

НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ ІМЕНІ ІГОРЯ
СІКОРСЬКОГО»
ІНСТИТУТ ПРИКЛАДНОГО СИСТЕМНОГО АНАЛІЗУ
КАФЕДРА МАТЕМАТИЧНИХ МЕТОДІВ СИСТЕМНОГО АНАЛІЗУ

На правах рукопису
УДК 004.932.4

До захисту допущено
В. о. завідувача кафедри ММСА
О.Л.Тимошук
«__» _____ 2020 р.

Магістерська дисертація

на здобуття ступеня магістра за спеціальністю 124 Системний аналіз
на тему: «Методика покращення якості зображень на основі генеративних
змагальних мереж»

Виконав:
студент II курсу, групи КА-92мп
Майко О. В.

Керівник:
професор кафедри ММСА,
д.т.н., проф. Данилов В.

Рецензент:
професор інформаційної безпеки
КПІ ім. Ігоря Сікорського,
д.т.н., проф. Качинський А. Б.

Засвідчую, що у цій магістерській дисертації
немає запозичень з праць інших авторів
без відповідних посилань

Студент _____

Київ
2020

НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ ІМЕНІ ІГОРЯ
СІКОРСЬКОГО»
ІНСТИТУТ ПРИКЛАДНОГО СИСТЕМНОГО АНАЛІЗУ
КАФЕДРА МАТЕМАТИЧНИХ МЕТОДІВ СИСТЕМНОГО АНАЛІЗУ

Рівень вищої освіти — другий (магістерський)
Спеціальність — 124 «Системний аналіз»

ЗАТВЕРДЖУЮ

В. о. завідувача кафедри ММСА

О. Л. Тимошук

«___» _____ 2020 р.

ЗАВДАННЯ

на магістерську дисертацію студента Майка Олексія Вікторовича

1. Тема дисертації: «Методика покращення якості зображень на основі генеративних змагальних мереж», науковий керівник дисертації Данилов Валерій Якович, д.т.н. проф., затверджені наказом по університету від «02» листопада № 3182-с.

2. Термін подання студентом дисертації: 15 грудня 2020 р.

3. Об'єкт дослідження: зображення низької роздільної здатності.

4. Предмет дослідження: генеративна змагальна мережа, метод супер роздільної здатності (Super-Resolution).

5. Перелік завдань, які потрібно розробити:

- 1) розглянути методи покращення якості зображень;
- 2) розробити модель для покращення якості зображень;
- 3) виконати експерименти стосовно покращення якості зображень з використанням GAN;
- 4) дати оцінку і практичне застосування отриманих результатів, сформулювати наукову новизну та перспективи виконання подальших досліджень.
- 5) розробити стартап-проект виведення на ринок результатів дослідження;

6. Орієнтовний перелік графічного (ілюстративного) матеріалу:

- 1). Схема GAN (рис.);
- 2). Приклади функціонування створеного програмного продукту (рис.);
- 3). Таблиці у розділі стартап-проекту

7. Дата видачі завдання: 05 вересня 2020 р.

Календарний план

№ з/п	Назва етапів виконання магістерської дисертації	Термін виконання етапів магістерської дисертації
1.	Концептуальний вступ дисертації. Формулювання об'єкта, предмета, цілі, завдань, новизни, практичної значущості результатів	05.09.2020—12.09.2020
2.	Перший розділ. Огляд літературно-інформаційних джерел. Понятійно-категоріальний апарат. Характеристика об'єкта	16.09.2020—27.09.2020
3.	Другий розділ. Генеративна змагальна нейронна мережна та її використання.	30.09.2020—19.10.2020
4.	Третій розділ. Пошук даних та реалізація алгоритму. Імплементация отриманих результатів у програмний продукт. Тестування програми	22.10.2020—15.11.2020
5.	Четвертий розділ. Стартап-проект	18.11.2020—20.11.2020
6.	Концептуальні висновки. Перспективи розвитку отриманих рішень	21.11.2020—25.11.2020

Студент

Майко О.В.

Науковий керівник дисертації

Данилов В.Я.

РЕФЕРАТ

Магістерська дисертація містить 127 с., 26 табл., 35 рис., 2 дод.. А також було використано 34 джерела.

КОМП'ЮТЕРНІ КОМУНІКАЦІЇ, КОМП'ЮТЕРНА БЕЗПЕКА ТА НАДІЙНІСТЬ, ОПЕРАЦІЙНІ СИСТЕМИ, ІНФОРМАЦІЙНІ СИСТЕМИ, ШТУЧНА НЕЙРОННА МЕРЕЖА, ШТУЧНИЙ ІНТЕЛЕКТ, МЕТОД ЗВОРОТНЬОГО ПОШИРЕННЯ ПОМИЛКИ, РОЗДІЛЬНА ЗДАТНІСТЬ ЗОБРАЖЕННЯ, ВІДНОВЛЕННЯ ЗОБРАЖЕНЬ, ПРИБИРАННЯ ШУМУ З ЗОБРАЖЕНЬ, ГЛИБОКІ ЗГОРТКОВІ НЕЙРОННІ МЕРЕЖІ, РОЗРІДЖЕНЕ КОДУВАННЯ.

В даній роботі розглядаються актуальні проблеми та питання у галузі покращення роздільної здатності зображень. Висока якість зображень є необхідним фактором при забезпеченні стабільної роботи записуючих пристроїв, а також відповідної частоти кадрів для динамічних сцен.

Метою даної роботи є дослідити існуючі підходи до покращення роздільної здатності зображень, покращити їх, розробити власний, який буде проявляти себе краще при вирішенні задачі та досягати компромісу між продуктивністю та швидкістю відпрацювання програмного продукту. Та порівняти результати роботи з використанням глибинних згорткових мереж, які використовувалися у дипломній роботі.

Об'єктом дослідження виступає тестовий набір даних зображень низької роздільної здатності.

Методи дослідження – генеративно-змагальна нейронна мережа, метод супер роздільної здатності (Super Resolution).

Програмний продукт реалізований за допомогою мови програмування Python. Після дослідження методу був проведений порівняльний аналіз між різними підходами для вирішення поставленої проблеми.

У виконаній роботі розроблено методику покращення роздільної здатності зображень на основі генеративно-змагальних нейронних мереж з використанням методу супер роздільної здатності. Пропонується спосіб, який забезпечує більшу швидкість при використанні на практиці та дає сучасну якість результату.

Галузь застосування: проведена робота може бути використана при підвищенні роздільної здатності зображень, особливо в таких областях, як відеоспостереження, медична діагностика, фермерське господарство та застосування дистанційного зондування.

ABSTRACT

Master's thesis contains 127 pages, 35 drawings, 26 tables. And also 34 sources were used.

COMPUTER COMMUNICATIONS, COMPUTER SECURITY AND RELIABILITY, OPERATING SYSTEMS, INFORMATION SYSTEMS, ARTIFICIAL NEURAL NETWORK, ARTIFICIAL INTELLIGENCE, BACKPROPAGATION, BINDING IMMUNITY, RESTORING IMAGES, IMAGE DENOISING, GENERATIVE ADVERSARIAL NEURAL NETWORKS, REDUCED CODING.

In this paper, the current problems and issues in the field of improving the resolution of images are considered. High quality images are a necessary factor in ensuring the stable operation of recorders, as well as the appropriate frame rate for dynamic scenes.

The purpose of this work is to investigate existing approaches to improving the resolution of images, improve them, develop our own, which will be better at solving the problem and reach a compromise between the productivity and speed of the software.

The object of research is a test set of low-resolution image data.

Methods of research - GAN, super resolution method.

The software product is implemented using the Python programming language. After studying the method, a comparative analysis was conducted between our and other approaches that were used to solve the problem.

In the work we have developed a method for improving the resolution of images based on deep convolutional neural networks using the super resolution method. A method is proposed that provides greater speed when used in practice and gives the contemporary quality of the result.

Field of application: The work can be used to increase the resolution of images, especially in areas such as video surveillance, medical diagnostics, farming and remote sensing applications.

ЗМІСТ

ПЕРЕЛІК ПРИЙНЯТИХ СКОРОЧЕНЬ	11
ВСТУП	12
РОЗДІЛ 1 ОСНОВНІ ВІДОМОСТІ НЕЙРОМЕРЕЖ	16
1.1 Вступ	16
1.2 Класичні методи машинного навчання, розпізнавання образів і комп'ютерного зору	17
1.3 Фільтрація	18
1.3.1 Бінаризація по порогу, вибір області гістограми	18
1.3.2 Перетворення Фур'є	19
1.3.3 Супер-роздільна здатність зображення	19
1.3.4 Проектування згорткових нейронних мереж	21
1.3.5 Функція втрат	22
1.3.6 Фільтри функцій	24
1.3.7 Фільтри контурів	25
1.3.8 Інші фільтри	25
1.4 Визначення нейромереж	26
1.5 Класифікація нейромереж	28
1.5.1 Багатошаровий перцептрон	28
1.5.2 Рекурентний перцептрон	30
1.5.3 Згорткові нейронні мережі	31
1.5.4 Мережа радіально-базисних функцій	34
1.5.5 Повно зв'язні нейронні мережі	35
1.5.6 Генеративно-змагальні нейронні мережі	36
1.5.7 Мережа Хопфілда	38
1.5.8 Нейронні мережі LSTM та GRU	40
1.5.9 Мережі Джордана і Елма	41
1.5.10 Самоорганізаційна карта Кохонена	42

1.5.11	Мережа Хеммінга	44
1.6	Класифікація нейромереж	45
1.7	Висновки до першого розділу	53
РОЗДІЛ 2 СТРУКТУРА ТА МЕТОДИ ГЕНЕРАТИВНО-ЗМАГАЛЬНИХ НЕЙРОМЕРЕЖ		55
2.1	Вступ	55
2.2	Генеративно-змагальні нейронні мережі	56
2.2.1	Архітектура	56
2.2.2	Генератор	58
2.2.3	Дискримінатор	59
2.2.4	Функція сприйняття втрат	59
2.2.5	Робота автокодерів	61
2.2.6	Втрата вмісту	63
2.2.7	Змагальний збиток	64
2.2.8	Поради із навчання GAN	64
2.3	Проблеми тренування	65
2.4	Як і де застосовується GAN і генеративні моделі	67
2.5	Генеративно-змагальна мережа Spade	71
2.6	Висновок і подальші дослідження	74
РОЗДІЛ 3 МОДЕЛЬ ПОКРАЩЕННЯ ЯКОСТІ ЗОБРАЖЕНЬ		75
3.1	Вступ	75
3.2	Дані на показники подібності	75
3.2.1	Підвищення варіативності шляхом стандартного відхилення	76
3.2.2	Деталі та параметри навчання	78
3.2.3	Робота над втратою вмісту	79
3.3	Висновки до третього розділу	81
РОЗДІЛ 4 РОЗРОБКА СТАРТАП-ПРОЕКТУ		82
4.1.	Опис ідеї проекту	83
4.2	Технологічний аудит ідеї проекту	85
4.3	Аналіз ринкової стратегії проекту	96

4.4	Розроблення маркетингової програми стартап-проекту	100
4.5	Висновки до четвертого розділу	105
	ВИСНОВКИ.....	107
	ПЕРЕЛІК ПОСИЛАНЬ	109
	ДОДАТОК А ЛІСТИНГ ПРОГРАМИ	113
	ДОДАТОК Б ПРЕЗЕНТАЦІЙНІ МАТЕРІАЛИ	114

ПЕРЕЛІК ПРИЙНЯТИХ СКОРОЧЕНЬ

СРЗ – супер-роздільна здатність

ВРЗ – висока роздільна здатність

НРЗ – низька роздільна здатність

ГЗМ – генеративно-змагальна мережа

ЗНМ – згорткова нейронна мережа

ІСП – структурна схожість

ПВСШ – пікове відношення сигналу до шуму

ЗМШР – згорткова мережа для широкомасштабного розпізнавання

ВСТУП

Generative Adversarial Networks (GAN) користуються все більшою популярністю. Багато хто говорить про них, хтось навіть вже використовує. Це алгоритм машинного навчання, що входить в сімейство породжують моделей і побудований на комбінації з двох нейронних мереж, одна з яких генерує зразки, інша намагається відрізнити справжні зразки від згенерованих.

GAN складається з одного дискримінатора та одного генератора. Дискримінатор намагається відрізнити реальні зразки від створених зразків, тоді як генератор підробляє реальні зразки, використовуючи інформацію від дискримінатора. GAN унікальна з багатьох інших генеративних моделей. Замість явної вибірки з розподілу ймовірностей GAN використовує глибоку нейронну мережу як прямий генератор, який генерує зразки з випадкових шумів.

Стратегічна підготовка GAN полягає у визначенні гри між двома конкуруючими мережами. Мережа генератора відображає джерело шуму до вхідного простору. Мережа дискримінатора отримує або згенерований зразок, або справжній зразок даних, і повинен розрізняти два. Генератор навчений дурити дискримінатора.

Принцип змагальності в мережі GAN нерідко описується через метафори. Наприклад, генеративна мережа уподібнюється фальшивомонетнику або підроблювач картин, а дискримінатор - експерту який прагне розпізнати підробку.

Незважаючи на прориви в точності та швидкості одна роздільна здатність одного зображення із використанням більш швидких та глибоких згорткових нейронних мереж, одна центральна проблема залишається в основному невирішена: як нам відновити деталі тоншої текстури коли ми вирішуємо з великими факторами збільшення масштабу? Поведінка методів

супер-роздільної здатності на основі оптимізації є головним чином обумовлена вибором цільової функції.

Останні роботи в основному зосереджувались на мінімізації середнього значення помилки реконструкції в квадраті. Отримані оцінки мають високі пікові коефіцієнти відношення сигналу до шуму, але їм часто бракує високочастотних деталей і сприймають сприйнятливо в відчуття того, що вони не відповідають вірності, яку очікували при використанні вищої роздільної здатності. У цій роботі я працював над генеративною змагальною мережею (ГЗМ) для супер-роздільної здатності (СРЗ) зображень. Наскільки наразі відомо, це перший фреймворк, який здатний виводити фотореалістичні природні зображення з 4-кратним фактором збільшення. Для досягнення цього я пропоную функцію сприйняття втрат, яка складається із змагальних втрат та втрати вмісту. Змагальні втрати підштовхують моє рішення до багатоманітного природного зображення, використовуючи дискримінаційну мережу, яка навчена розрізняти супер-роздільні зображення та оригінальні фотореалістичні зображення. Крім того, я використовую втрату вмісту, мотивовану сприйняттям подібності, замість схожості в піксельному просторі. Дана глибока залишкова мережа здатна відновити фотореалістичні текстури з сильно зменшених зображень на загальнодоступних тестах. Широкий тест оцінки середньої оцінки (ОСО) показує надзвичайно значне підвищення якості сприйняття за допомогою генеративної змагальної мережі для супер-роздільної здатності зображень (СРГЗМ). Оцінки ОСО, отримані за допомогою СРГЗМ, ближчі до оцінок оригінальних зображень із високою роздільною здатністю, ніж до оцінок, отриманих за допомогою будь-якого іншого сучасного методу.

Дуже складне завдання створення зображення з високою роздільною здатністю (ВРЗ) за його аналогом із низькою роздільною здатністю (НРЗ) називається супер-роздільною здатністю (СРЗ). СРЗ отримав значну увагу з боку спільноти дослідників комп'ютерного зору і має широкий спектр застосувань [1]

4x SRГЗМ / Оригінальне зображення




Рисунок 1: Супер-роздільне зображення (ліворуч) майже не відрізняється від оригіналу (праворуч). [4 × збільшення масштабу]

Неправильний характер невизначеної проблеми СРЗ особливо яскраво виражений для високих коефіцієнтів збільшення, для яких деталізація текстури у реконструйованих зображеннях СРЗ зазвичай відсутня. Завданням оптимізації керованих алгоритмів СРЗ зазвичай є мінімізація середньої квадратичної помилки (СКП) між відновленим зображенням високої роздільної здатності та оригінальним зображенням. Це зручно, оскільки мінімізація СКП також максимізує пікове відношення сигнал / шум (ПВСШ), що є загальним показником, що використовується для оцінки та порівняння алгоритмів СРЗ [2]. Однак здатність СКП (та ПВСШ) фіксувати сприйнятливі до сприйняття відмінності, такі як висока деталізація текстури, дуже обмежена, оскільки вони визначаються на основі піксельних відмінностей зображення [3]. Це проілюстровано на малюнку 2, де найвищий показник ПВСШ не обов'язково відображає кращий результат сприйняття.




Рисунок 2: Результати роботи різних методів [4× збільшення масштабу]

Зліва направо: бікубічна інтерполяція, глибока залишкова мережа, оптимізована для СКП, глибока залишкова генеративна змагальна мережа, оптимізована для втрат, більш чутливих до сприйняття людиною, оригінальне зображення ВРЗ. Відповідні ПБСШ та індекс структурної подібності (ІСП) наведені в дужках.

Ключова різниця між супер-роздільним та оригінальним зображенням означає, що відновлене зображення не є фотореалістичним, як визначено Фервердою [4]. У цій роботі я пропоную генеративну змагальну мережу з надвисокою роздільною здатністю (СРГЗМ), для якої ми використовуємо глибоку залишкову мережу (ResNet) з пропуском підключення та відхиленням від СКП як єдиною метою оптимізації. На відміну від попередніх робіт, я визначаю нові сприйнятливі втрати, використовуючи високорівневі карти функцій дуже глибокої згорткової мережі для широкомасштабного розпізнавання зображень [5] у поєднанні з дискримінатором, який заохочує рішення, які важко відрізнити від зображень високої роздільної здатності. Приклад фотореалістичного зображення з використанням супер-роздільної здатності, яке було опрацьовано з коефіцієнтом збільшення 4 ×, зображено на рисунку 1.

У цій магістерській дисертації буде розглянуто методи покращення якості зображень за допомогою ГЗМ.

РОЗДІЛ 1 ОСНОВНІ ВІДОМОСТІ НЕЙРОМЕРЕЖ

1.1 Вступ

Машинне навчання - це великий підрозділ теорії штучного інтелекту, суворо математична дисципліна, яка використовує розділи математичної статистики, чисельних методів оптимізації, теорії ймовірностей [6].

Існує два типи машинного навчання: навчання по прецедентах (індуктивне навчання), засноване на емпіричних даних, і дедуктивний навчання, що припускає формалізацію знань і формування бази знань. Дедуктивне навчання прийнято відносити до області експертних систем, тому в теорії і практиці машинного навчання фактично розглядається навчання по прецедентах.

Розділ машинного навчання виник в результаті поділу науки про нейронних мережах в рамках науки про штучний інтелект на методи навчання мереж і види топології архітектури мереж, увібравши в себе деякі інші області, такі як методи математичної статистики і теорію дискретного аналізу [7].

Специфіка розглянутих способів навчання в рамках дисципліни обумовлена:

- навчання з учителем - для кожного прецеденту існує пара «ситуація, рішення»;
- навчання без вчителя - система групує об'єкти в кластери і знижує розмірність вхідної інформації, використовуючи дані про попарному схожості;
- навчання з підкріпленням - для кожного прецеденту існує пара «ситуація, реакція середовища» (навчання з підкріпленням можна вважати окремим випадком навчання з учителем, так і окремим випадком навчання без вчителя).

Існують також інші, менш поширені способи навчання, наприклад, активне навчання (той, якого навчають алгоритм має можливість призначити наступну досліджувану ситуацію), часткове залучення вчителя, трансдуктивне навчання, багатозадачність і різноманітне навчання, але відмінності в цих способах несуттєві в рамках даної проблеми.

Всі перераховані способи можна використовувати для класифікації традиційних методів машинного навчання і для класифікації алгоритмів навчання нейронних мереж, що реалізують будь-який з них.

Сучасне машинне навчання стикається з гострою проблемою універсальності, оскільки практично не існує однорідного простору алгоритмів і методу загального вирішення проблеми індукції [8].

1.2 Класичні методи машинного навчання, розпізнавання образів і комп'ютерного зору

Тут і далі теорія комп'ютерного зору, теорія розпізнавання образів, теорія машинного навчання і обробка зображень будуть розглядатися в сенсі розпізнавання образів в комп'ютерному зорі. В іншому випадку буде зазначений інший сенс. З метою стислості може згадуватися тільки одна з цих дисциплін в залежності від контексту.

Класичні методи комп'ютерного зору, розпізнавання образів і машинного навчання можна умовно розділити на три групи:

- методи фільтрації;
- методи аналізу;
- методи навчання.

Основні класичні методи реалізовані в бібліотеці OpenCV, написаної на C / C ++, і займає домінуюче становище при вирішенні задач комп'ютерного зору з використанням класичних підходів.

1.3 Фільтрація

У завданнях комп'ютерного зору фільтрація найчастіше використовується для попередньої обробки зображення перед аналізом його внутрішніх морфологічних ознак, але зустрічаються і завдання, в яких достатнім і бажаним буде використання тільки фільтрації як такої (наприклад, в задачах машинного зору).

1.3.1 Бінаризація по порогу, вибір області гістограми

Для RGB зображення і зображення в градаціях сірого порогом є значення кольору. Вибір порога, за яким відбувається бінаризація, багато в чому визначає процес бінаризація. Зазвичай бінаризація здійснюється за допомогою адаптивного алгоритму, що вибирає поріг. Таким алгоритмом може бути вибір математичного очікування, моди або піків гістограми. При роботі з гістограмою бінаризація ефективна для сегментації квітів.

1.3.2 Перетворення Фур'є

Перетворення Фур'є майже не використовується при обробці зображень в чистому вигляді, оскільки для аналізу зображень одновимірного перетворення зазвичай не вистачає і виникає необхідність використання куди більш ресурсоємних двовимірного перетворення. Цей метод застосовується тільки в разі якщо необхідний аналіз спектра, оскільки використання згортки цікавить області з уже готовим фільтром виявляється швидше і простіше в реалізації. Тим не менше, одномірне перетворення Фур'є застосовується при компресії зображень [9].

1.3.3 Супер-роздільна здатність зображення

Нещодавні оглядові статті про зображення СРЗ включають авторства Насулахі та Муслунда [10] або Янга [11]. Тут ми зосередимося на супер-роздільній здатності одного зображення (СРЗОЗ) і не будемо далі обговорювати підходи, що дозволяють відновити зображення високої роздільної здатності з кількох зображень [11].

Методи, засновані на прогнозі, були одними з перших методів боротьби з СРЗОЗ. Поки ці фільтрації підходять, наприклад лінійна, бікубічна або фільтрація Ланчоса [11], може бути дуже швидкою, вони спрощують проблему СРЗОЗ і зазвичай дають рішення із надто гладкими текстурями. Запропоновано методи, що приділяють особливу увагу збереженню країв зображень [12].

Більш потужні підходи мають на меті створити складне відображення між інформацією про зображення із низькою та високою роздільною здатністю і, як правило, покладаються на дані навчання.

Багато методів, заснованих на прикладних парах, покладаються на навчальні патчі НРЗ, для яких відомі відповідні аналоги ВРЗ. З подібними методами, наприклад, працював відомий автор Фрімен [12]. Супутні підходи до проблеми СРЗ походять із стисненого зондування [12]. У роботі Гласнер та співавтори [13] використовують надмірність виправлень у масштабах зображення, щоб керувати СРЗ зображень. Ця парадигма самоподібності також застосовується у Хуанга та інших [14], де самословники розширені, додатково дозволяючи невеликі трансформації та варіації форми. Гу [15] запропонував згорнутий підхід розрідженого кодування, який покращує узгодженість, обробляючи ціле зображення, а не перекриваючі патчі.

Для реконструкції реалістичних деталей текстури, уникаючи крайових артефактів, Тай та співавтори [15] поєднують керований на краю алгоритм СРЗ зображень на основі градієнтного профілю з перевагами синтезу деталей на основі навчання. Чжан та ін. [15] пропонують багатомасштабний словник для фіксації надмірностей подібних патчів зображень у різних масштабах. Для надмірного вирішення орієнтирів, Юе та ін. [16] отримують з Інтернету корелюючі зображення ВРЗ із подібним вмістом і пропонують структурований критерій відповідності для вирівнювання.

Вбудовування сусідства підходить до вибірки патча зображення НРЗ шляхом пошуку подібних навчальних патчів низької роздільної здатності у низькорозмірному колекторі та комбінування відповідних патчів ВРЗ для реконструкції. У роботі Кім та Квон [17] автори підкреслюють тенденцію сусідських підходів до переобладнання та формулюють більш загальну карту пар прикладів з використанням регресії ядра зображення. Проблему регресії також можна вирішити за допомогою регресії процесу Гауса, дерев або випадкових лісів. У Дая та співавторів [18] вивчається безліч специфічних регресорів та підбираються найбільш підходящі регресори під час тестування.

У своїй попередній роботі алгоритми ВРЗ на основі глибинних згорткових нейронних мереж (ЗНМ) показали чудові показники. Також у роботі Уанга [19] автори кодують розріджене представлення в свою

архітектуру мережі зворотного зв'язку на основі вивченого ітеративного алгоритму усадки та порогового значення (BIAУПЗ). Донг та ін. [19] використовував бікубічну інтерполяцію для збільшення масштабу вхідного зображення і навчив тришарову глибину повністю згорнутої мережі наскрізно для досягнення найсучасніших характеристик SR. Згодом було продемонстровано, що надання можливості мережі безпосередньо засвоїти фільтри підвищення масштабу може додатково підвищити продуктивність як з точки зору точності, так і швидкості. З їх глибоко-рекурсивною згортковою мережею (ГРЗНМ) Кім представив вискоєфективну архітектуру, яка дозволяє мати залежність від дальніх пікселів, зберігаючи малу кількість параметрів моделі. Для нашої роботи особливу актуальність мають роботи Джонсона та Бруно [20], які покладаються на функцію втрат ближче до перцептивної подібності, щоб відновити візуально більш переконливі зображення ВРЗ зображень.

1.3.4 Проектування згорткових нейронних мереж

Сутність багатьох проблем із комп'ютерним зором визначається спеціально розробленими архітектурами ЗНМ після успіхів які у своїх роботах описав Крижевський та співавтори.

Було показано, що глибші мережеві архітектури можуть бути важкими для навчання, але мають потенціал суттєво підвищити точність мережі, оскільки вони дозволяють моделювати відображення дуже високої складності. Для ефективної підготовки цих глибших архітектур мережі частотна нормалізація часто використовується для протидії внутрішньому зміненню ко-змінних. Також було продемонстровано, що більш глибокі архітектури мережі підвищують продуктивність для СРЗОЗ. Наприклад, у своїй праці Кім сформулював рекурсивну згорткову нейронну мережу та представив найкращі

та найсучасніші результати. Ще один потужний архітектурний вибір, який полегшує навчання глибоких згорткових мереж - це нещодавно введена концепція залишкових блоків та пропусків. Пропуски полегшують мережеву архітектуру при моделюванні ототожнення ідентичності, яке є тривіальним за своєю суттю, однак потенційно нетривіальним для представлення за допомогою згорткових ядер.

У контексті СРЗОЗ також було показано, що вивчення фільтрів підвищення масштабу є вигідним з точки зору точності та швидкості [21]. Це покращення порівняно з працею Донга де бікубічна інтерполяція використовується для збільшення масштабу спостереження НРЗ перед подачею зображення на ЗНМ.

1.3.5 Функція втрат

Функції піксельних втрат, такі як СКП, намагаються впоратись з невизначеністю, що притаманна відновленню втрачених високочастотних деталей, таких як текстура: мінімізація СКП заохочує знаходити піксельні середні значення правдоподібних рішень, які, як правило, надмірно плавні і, отже, мають низьку якість сприйняття. Реконструкції різної якості сприйняття наведені на прикладі відповідного ПВСШ на малюнку 2. Ми ілюструємо проблему мінімізації СКП на рисунку 3, де для усебічного відновлення узагальнено багато потенційних рішень із високими деталями текстури.




Рисунок 1.1: Ілюстрація плям із колектора природного зображення (червоний) та суперрозрішених плям, отриманих за допомогою СКП (синій) та СКП (оранжевий)

Рішення на базі СКП виглядає надмірно гладким через середнє значення пікселів можливі рішення у піксельному просторі, тоді як ГЗМ рухає реконструкцію до природного різноманіття зображення, виробляючи сприйнятливо більш переконливі рішення.

У роботах Метью та Дентона автори вирішили цю проблему, використовуючи генеративні змагальні мережі (ГЗМ) [22] для застосування генерації зображень. Ю і Поріклі збільшують піксельні втрати СКП з дискримінатором, щоб навчити мережу, яка супер-роздільною здатністю дозволяє використовувати зображення обличчя з великими коефіцієнтами збільшення (8x). Різноматні види ГЗМ також використовувались для вивчення вибірок без наглядача у праці Редфорда. Ідея використання ГЗМ для вивчення відображення з одного колектора на інший описана Лі та Вандом для передачі стилю та праці Еха для фарбування. Бруно мінімізував квадратну помилку в

просторах характеристик дуже глибоких згорткових мережах для широкомасштабного розпізнавання зображень (ЗМШР) та розсіяних мережах.

Досовицький та Брокс використовують функції втрат на основі евклідових відстаней, обчислених у просторі характеристик нейронних мереж у поєднанні з змагальним навчанням. Показано, що запропоновані втрати дозволяють візуально покращити генерацію зображення і можуть бути використані для вирішення некоректної зворотної проблеми декодування нелінійних подань ознак. Подібно до цієї роботи, Джонсон та Бруно пропонують використовувати функції, витягнуті з попередньо навченої (ЗМШР), замість низькорівневих показників помилок. Зокрема, автори формулюють функцію втрат на основі евклідової відстані між картами об'єктів, витягнутими з ЗМШР. Концептуально більш переконливі результати були отримані як для супер-роздільної здатності, так і для передачі художнього стилю. Нещодавно Лі та Ванд також досліджували ефект порівняння та змішування патчів у просторі об'єктів пікселів або ЗМШР.

1.3.6 Фільтри функцій

У цьому підході використовуються математичні фільтри, що дозволяють виявляти прості математичні функції на зображенні, для чого формується акумулює зображення (накопичувальний простір), в якому для кожної точки вихідного зображення будується безліч породжують її функцій.

Класичним прикладом є узагальнена перетворення Хафа, що застосовується до бінаризованими зображень, що дозволяє знаходити на зображенні будь-які параметризуємих функції. Модифіковане перетворення Хафа дозволяє шукати будь-які фігури, але в обробці зображень його використання пов'язане з недостатньою стабільністю: висока чутливість до якості бінаризація і низька швидкість роботи змушують шукати цього методу

більш ефективні альтернативи. Аналогом перетворення Хафа для прямих є перетворення Радону, що застосовується до небінарізованим зображень і обчислюється через БПФ, що дає значний виграш в продуктивності на великих масивах даних.

1.3.7 Фільтри контурів

Фільтри контурів дуже корисні при вирішенні задач комп'ютерного зору в разі якщо необхідна реалізація обробки складних об'єктів на зображенні. Фільтрацію контурів реалізує ряд алгоритмів, таких як: оператор Кенні, який є найбільш часто використовуваним алгоритмом пошуку контурів, оператор Собеля, оператор Лапласа, оператор Прюїтт, оператор Робертса. Алгоритм Кенні реалізує поняття придушення немаксимумов, що означає, що пікселями кордонів оголошуються пікселі, в яких досягається локальний максимум градієнта в напрямку вектору градієнта. В комп'ютерному зорі і обробці зображень при пошуку меж об'єктів крім особливих окремих випадків важко знайти детектор, який би працював істотно краще, ніж детектор Кенні.

1.3.8 Інші фільтри

Модифікації вищевказаних фільтрів дозволяють вирішити переважна кількість завдань фільтрації на рівні класичних методів, але крім них існують десятки більш спеціалізованих алгоритмів фільтрації, на практиці використовуються значно рідше.

Найбільш цікавими є ітераційні фільтри, такі як активна модель зовнішнього вигляду, ріджлет перетворення, курвлет-перетворення, що

виникли на основі класичних вейвлет-функцій і аналізу в поле перетворення Радону, бімлет-перетворення, що реалізує частково завдання фільтрації, частково – завдання аналізу, що дозволяє знаходити контури об'єктів. Ці фільтри володіють рідкісною специфікою і в силу своєї вузької спрямованості не розглядатимуться в рамках даної роботи докладніше.

1.4 Визначення нейромереж

Нейронна мережа - це послідовність нейронів, з'єднаних між собою синапсами. Структура нейронної мережі прийшла в світ програмування прямо з біології. Завдяки такій структурі, машина отримує можливість аналізувати і навіть запам'ятовувати різну інформацію. Нейронні мережі також здатні не тільки аналізувати вхідну інформацію, а й відтворювати її зі своєї пам'яті. Іншими словами, нейронна мережа це машинна інтерпретація мозку людини, в якому знаходяться мільйони нейронів передають інформацію у вигляді електричних імпульсів.

Найважливішим властивістю нейронних мереж є їх здатність навчатися на основі даних навколишнього середовища і в результаті навчання підвищувати свою продуктивність. Підвищення продуктивності відбувається з часом відповідно до певних правил. Навчання нейронної мережі відбувається за допомогою інтерактивного процесу коригування синоптичних ваг і порогів. В ідеальному випадку нейронна мережа отримує знання про навколишнє середовище на кожній ітерації процесу навчання.

З поняттям навчання асоціюється досить багато видів діяльності, тому складно надати цьому процесу однозначне визначення. Більш того, процес навчання залежить від точки зору на нього. Саме це робить практично неможливим появу будь-якого точного визначення цього поняття. Наприклад,

процес навчання з точки зору психолога в корені відрізняється від навчання з точки зору шкільного вчителя.

Нейронні мережі використовуються для вирішення складних завдань, які вимагають аналітичних обчислень подібних тим, що робить людський мозок.

Найпоширенішими застосуваннями нейронних мереж є:

- класифікація;
- передбачення;
- розпізнавання.

Класифікація - розподіл даних по параметрах. Наприклад, на вхід дається набір людей і потрібно вирішити, кому з них давати кредит, а кому ні. Цю роботу може зробити нейронна мережа, аналізуючи таку інформацію як: вік, платоспроможність, кредитна історія. Передбачення - можливість прогнозувати наступний крок. Наприклад, зростання або падіння акцій, ґрунтуючись на ситуації на фондовому ринку. Розпізнавання - в даний час, саме широке застосування нейронних мереж. Використовується в Google, коли ви шукаєте фото або в камерах телефонів, коли воно визначає положення вашого обличчя і виділяє його і багато іншого [23].

Штучна нейронна мережа є концептуальною моделлю біологічної нейронної мережі і складається з пов'язаних різним чином шарів штучних нейронів, які організовують загальну активну структуру і функціонально впливають на роботу один до іншого. У більшості архітектур ІНС активність нейрона визначається перетворенням зовнішнього сумарного впливу інших нейронів на даний нейрон.

З моменту свого зародження технології штучних нейронних мереж розвивалися досить відокремленим від класичних методів шляхом, нерідко докорінно змінюючи уявлення про предмет в сукупній проблематики теорій машинного навчання і розпізнавання образів, роблячи значний вплив на теоретичний, термінологічний і методологічний апарати цих дисциплін. З

цього часу в науковому співтоваристві сталося кілька спадів і підйомів інтересу до цього напрямку, але, завдяки деяким проривів в теорії ІНС, широке практичне застосування непромережені технології отримали порівняно недавно.

1.5 Класифікація нейромереж

В цьому розділі було розроблено методи обробки даних для подальшого тренування моделей. А саме, як шукати аномалії чи викиди в даних, як вирішувати проблему з високою корельованістю змінних і їх вплив на моделі. А також, як можна нормалізувати чи стандартизувати тренувальні данні. Даний процес аналізу і обробки даних, як правило, найбільш громіздкий по часу для рішення типових задач.

1.5.1 Багатошаровий перцептрон

Найвідоміша та дуже стара архітектура, в основі якій йдуть підряд кілька шарів нейронів - вхідний, один або кілька прихованих шарів, і вихідний шар. Нейрони кожного шару з'єднуються з нейронами попереднього і наступного шарів за принципом "кожний з кожним". Кількість нейронів у шарах може бути довільною. Звичайно у всіх схованих шарах однакова кількість нейронів. Майже завжди навчається методом зворотного поширення помилки - що автоматично означає, що потрібно надати для навчання набір пар «вхідний вектор - правильний вихід». Існує плутанина з підрахунком кількості шарів у мережі. Вхідний шар не виконує ніяких обчислень, а лише розподіляє вхідні сигнали, тому іноді його вважають, іноді — немає.

Тоді вхідний вектор відправиться на вхід мережі, послідовно будуть розраховані стану всіх проміжних нейронів, і на виході утворюється вихідний вектор, який порівнюємо з правильним. Розбіжність дасть нам помилку, яку можна поширити назад зі зв'язків мережі, обчислити внесок в підсумкову помилку кожного нейрона, і скорегувати його ваги, щоб її виправити. Повторивши цю процедуру багато тисяч разів, можливо вийде навчити мережу.

Кожен шар розраховує нелінійне перетворення від лінійної комбінації сигналів попереднього шаруючи. Звідси видно, що лінійна функція активації може застосовується тільки для тих моделей мереж, де не потрібно послідовне з'єднання шарів нейронів один за одним.

Для багатошарових мереж функція активації повинна бути нелінійною, інакше можна побудувати еквівалентну одношарову мережу, і багатошаровість виявляється непотрібною. Якщо застосована лінійна функція активації, де кожен шар буде давати на виході лінійну комбінацію входів.

Слідуючий шар дасть лінійну комбінацію виходів попереднього, а це еквівалентно однієї лінійної комбінації з іншими коефіцієнтами, і може бути реалізоване у виді одного шару нейронів.

Багатошарова мережа може формувати на виході довільну багатомірну функцію при відповідному виборі кількості шарів, діапазону зміни сигналів і параметрів нейронів.

Мережа такого типу зазвичай дуже добре справляється з завданнями, де:

- відповідь дійсно залежить тільки від того, що надано на вхід до мережі, і ніяк не залежить від історії входів (тобто це не динамічний процес, або, принаймні, надали на вхід вичерпну інформацію про цей процес у формі, яка більш підходить для обробки мережею);

- відповідь не залежить або слабо залежить від високих ступенів i / або творів параметрів – але функції цього типу мережу будувати майже не вміє;

– в наявності є досить багато прикладів (бажано мати не менше сотні прикладів на кожен зв'язок мережі), або у вас є великий досвід боротьби з ефектом спеціалізації.

Це пов'язано з тим, що маючи багато коефіцієнтів, мережа може банально запам'ятати багато конкретних прикладів, і видавати на них відмінний результат - але її прогнози не матимуть нічого спільного з реальністю в разі, якщо дати на вхід приклади не з навчальної вибірки.

Сильні сторони - вивчена з усіх боків, добре працює на своїх завданнях, якщо на деякій задачі не працює - то це привід стверджувати, що завдання складніше, ніж здавалося.

Слабкі сторони - невміння працювати з динамічними процесами, необхідність великої навчальної вибірки.

Перспективи - ніяких істотних. Більшість серйозних завдань, які все ще потребують вирішення, не входять до класу задач, що вирішуються багатосаровим перцептроном з методом зворотного поширення помилки.

1.5.2 Рекурентний перцептрон

На перший погляд схожий на звичайний перцептрон, єдина істотна відмінність полягає в тому, що його виходи потрапляють йому ж на входи, і беруть участь в обробці вже наступного вхідного вектора. Тобто, в разі поворотного перцептрону має місце не набір окремих, нічим не пов'язаних образів, а певний процес, і значення мають не тільки самі входи, але і те, в якій послідовності вони надходять.

Через це виникають відмінності в методі навчання - використовується те ж саме зворотне поширення помилки, але для того, щоб помилка потрапила по рекурентного зв'язку в минуле, використовуються різні хитрощі (якщо підійти до завдання «в лоб» - то виникне проблема догляду помилки на нескінченне

число циклів назад). В іншому ж ситуація схожа на звичайний перцептрон - для навчання потрібно мати достатньо довгу послідовність пар вхід-вихід, яку потрібно багато раз прогнати через мережу, щоб її навчити (або ж мати під рукою мат. Модель шуканого процесу, яку можна ганяти у всіляких умовах, і в реалтайм давати результати мережі для навчання).

Мережа такого типу зазвичай добре вирішує завдання управління динамічними процесами (починаючи від класичної завдання стабілізації перевернутого маятника, і до будь-яких систем, якими взагалі хоч якось виходить управляти), передбачення динамічних процесів, крім курсу валют, і взагалі всього, де крім явно спостерігається входу у системи є деякий внутрішній стан, яке не зовсім зрозуміло як використовувати.

Сильні сторони: мережа дуже хороша для роботи з динамічними процесами.

Слабкі сторони: якщо все ж не працює, зрозуміти в чому проблема - дуже важко, в процесі навчання може вилетіти в самозбудження (коли сигнал, отриманий з виходу, забиває все, що приходить по входах), якщо рішення все ж отримано - складно зрозуміти, чи можна домогтися кращих результатів, і яким шляхом. Іншими словами, погано вивчена.

Перспективи: цей підхід явно не вичерпав себе в питаннях управління - власне, на даний момент рекурентні перцептрони використовуються досить рідко, хоча їх потенціал високий. Цікаві результати може дати підхід з безперервно адаптується до об'єкта управління мережею, хоча для цього ще необхідно вирішити проблему нестійкості.

1.5.3 Згорткові нейронні мережі

Згорткові нейронні мережі - це багатошарові ІНС прямого поширення, що складаються з великої кількості перцептронів. У загальному випадку

згорткова нейронна мережа складається з ланцюжка декількох згортальних шарів, які використовуються для виділення ознак, і декількох повно зв'язних шарів.

Запропонована Яном Лекуном в 1988 році, входить до складу технологій глибинного навчання. В основі згортальних нейронних мереж лежать такі ідеї:

- кожен нейрон шару отримує вхідний сигнал від локального рецептивного поля в попередньому шарі. Під рецептивним полем розуміється шар нейронів, що сприймають зовнішні сигнали і передають їх наступного шару.

При цьому рецептивне поле безпосередньо взаємодіє з наступним шаром;

- кожен прихований шар нейронної мережі складається з безлічі карт ознак (feature maps). У них всі нейрони мають загальні ваги;

- за кожним шаром згортки слід обчислювальний шар, який здійснює локальне усереднення карт і просторову підвибірку.

При обчисленні мережі виходить, що кожен нейрон виконує операцію згортки (Конволюція) деякої області попереднього шару, яка визначається безліччю нейронів, пов'язаних з даними нейроном. Шари нейронної мережі, побудовані таким чином, називаються згортковими шарами. Крім, згортальних шарів в згортковій нейронній мережі можуть бути шари субдіскретизація і повно зв'язні шари. Шари субдіскретизація виконують функції зменшення розмірності простору карт ознак. Даний шар дозволяє прискорити подальші обчислення. субдіскретизація можливо завдяки тому, що в цій архітектурі нейронних мереж важливо не стільки значення ознаки, скільки сам факт його наявності. Вихідний шар згорткової нейронної мережі, як правило, завжди повно зв'язну. Нейрони цього шару мають повне з'єднання з усіма активації попереднього шару. Всі три види шарів можуть чергуватися в довільному порядку. Це дозволяє складати карти ознак з карт ознак, що на

практиці означає здатність розпізнавання складних ієрархій ознак. Це дозволяє від конкретних особливостей вхідних даних до абстрактних деталей.

При навчанні нейронних мереж зазвичай використовується метод зворотного поширення помилки (Backpropagation) або його модифікації. Суть даного методу полягає в тому, що поширення сигналів помилки в ІНС походить від виходів мережі до її входів, в напрямку, зворотному прямому поширенню сигналів. Даний вид нейронних мереж дуже добре зарекомендував себе для вирішення безлічі завдань обробки зображень [15].

Однією з найбільш відомих моделей згортальних мереж, що застосовуються для вирішення завдання збільшення зображень, є розроблена в 2014 році модель нейронної мережі SRCNN (Super-Resolution Convolutional Neural Network) [16]. На вхід SRCNN подається зображення, збільшене за допомогою методів інтерполяції, яке потім проходить процес поліпшення якості. Подібний метод застосовується в розробленому компанією Google методі RAISR [17]. Існують безліч модифікацій даної моделі, одними з найшвидших за швидкістю і ефективних за якістю є VDSR (Very Deep Convolutional Network) [17] і FSRCNN (Fast Super-Resolution Convolutional

Neural Network) [18]. Також заслуговує на увагу модель ESPCN (Efficient SubPixel Convolutional Neural Network) [18], яка здатна в реальному часі збільшувати зображення. На відміну від SRCNN, на вхід подається не 18 збільшене за допомогою інтерполяції зображення, а зображення низького дозволу. Збільшення розмірів зображення відбувається в результаті роботи нейронної мережі.

1.5.4 Мережа радіально-базисних функцій

Нейронна мережа прямого поширення сигналу, яка містить проміжний (прихований) шар радіально симетричних нейронів. Такий нейрон перетворює відстань від даного вхідного вектору до відповідного йому "центру" по деякому нелінійному закону (зазвичай функція Гаусса). Мережа радіально-базисних функцій зображена на рисунку 1.1.




Рисунок 1.1 - Мережа радіально-базисних функцій

Радіально-базисна мережа характеризується трьома особливостями:

- єдиний прихований шар;
- тільки нейрони прихованого шару мають нелінійну активаційну функцію;
- синаптичні ваги зв'язків вхідного і прихованого шарів дорівнюють одиниці.

1.5.5 Повно зв'язні нейронні мережі

Повно зв'язні нейронні мережі мають шарувату будову, при якому кожен нейрон поточного шару має зв'язки з усіма нейронами попереднього шару. Мережа складається з довільного числа шарів. Розрізняють вхідний шар - на який надходить вектор (зазвичай він не враховується у підрахунку шарів), вихідного шару, який видає результат розрахунків мережі і прихованих шарів. Вхідний шар не виконує ніяких обчислень - він просто розподіляє вектор на наступний шар і служить приймачем інформації. Зазвичай, якщо прихованих шарів більше, ніж два, то у всіх прихованих шарах однакову кількість нейронів.

Кожен шар розраховує нелінійне перетворення від лінійної комбінації сигналів попереднього шару. Багат шарова нейронна мережа може формувати на виході довільну багатовимірну функцію при відповідному виборі кількості шарів, діапазону зміни сигналів і параметрів нейронів. Багат шарові нейронні мережі є універсальним апроксиматором функцій. Даний тип мереж здатний успішно вирішувати широкий спектр завдань і широко застосовується через свою простоту.

Однак, застосовні вони не до всіх даних: повно зв'язні мережі несприйнятливі до інваріантним даними і не здатні розпізнавати образи при різному їх розташуванні вхідного вектора. Складність навчання даної моделі полягає в тому, що, по-перше, необхідно навчати відразу дві нейронних мережі, а по-друге, необхідно правильно налаштувати баланс між ними. Генератор навчається створювати більш якісний результат, дискримінатор навчається розпізнавати реальні дані від згенерованих. Так само можливості даного виду мереж дуже сильно залежать від кількості шарів: при наявності менше трьох шарів мережа не здатна до класифікації нелінійно розділених об'єктів. Топологія мережі розташована на рисунку 1.2.




Рисунок 1.2 - Мережа прямого поширення сигналу

1.5.6 Генеративно-змагальні нейронні мережі

Генеративно-змагальні мережі - це алгоритм машинного навчання без учителя, побудований на комбінації з двох нейронних мереж, як правило згортальних або прямого поширення

Перша мережа (генератор) генерує зразки. Друга мережа (дискримінатор) приймає на вхід результати роботи першої мережі і правильні («справжні») дані, а потім намагається відрізнити справжні зразки від згенерованих. Вперше ця модель була описана співробітниками компанії Google в 2014 році.

Складність навчання даної моделі полягає в тому, що, по-перше, необхідно навчати відразу дві нейронних мережі, а по-друге, необхідно правильно налаштувати баланс між ними. Генератор навчається створювати більш якісний результат, дискримінатор навчається розпізнавати реальні дані від згенерованих.

Якщо одна з мереж буде навчена краще, ніж інша, то модель в цілому не буде працювати коректно. Модель навчається методом зворотного поширення помилки.

Для навчання зазвичай використовується наступний алгоритм:

- проводиться підготовка реальних даних. У задачі збільшення зображень - це вихідні зображення, до яких не було застосовано масштабування;
- генерується шум, на базі якого генератор генерує дані;
- формується набір даних для навчання дискримінатора. Цей набір який складається зі справжніх даних, підготовлених на кроці 1 (їм присвоюється мітка 1) і підробок від генератора, отриманих на попередньому кроці (їм присвоюється мітка 0);
- проводиться навчання дискримінатора, в процесі якого на вхід подаються реальні дані і створені генератором;
- проводиться навчання генератора. На даному етапі навчається генератор, а навчання дискримінатора відключено. На вхід подається шум, на виході очікується отримання позначки 1. Розпізнавання дискримінатором даних як реальних. При навчанні генератора не використовуються реальні зображення, а використовується тільки відмітка дискримінатора. Схема моделі змагальної мережі представлена на рисунку 1.3.

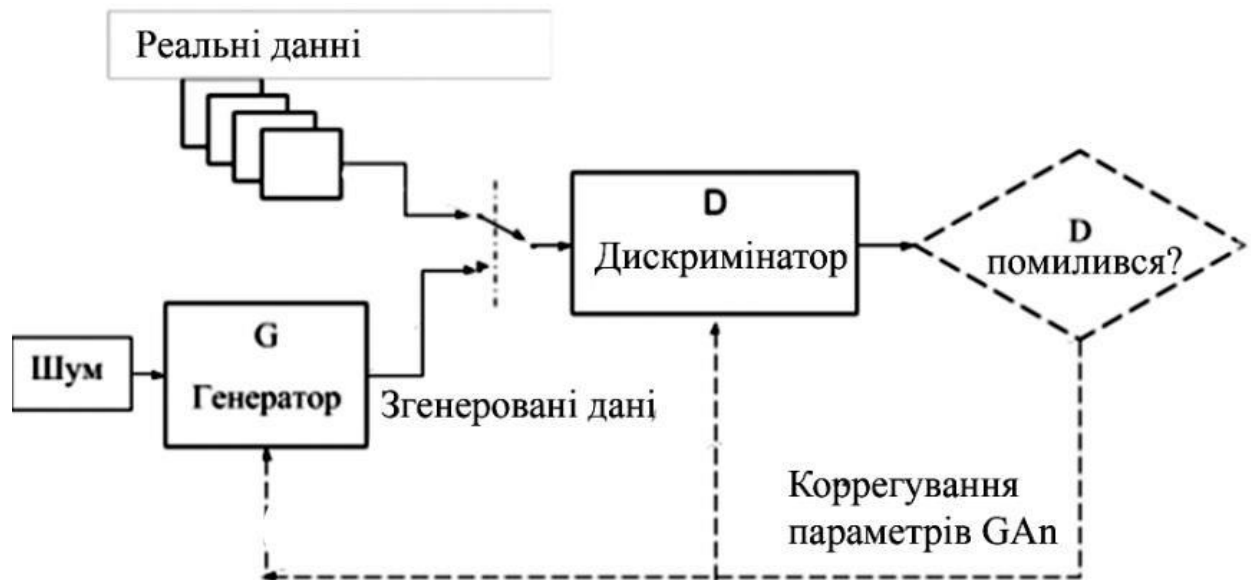


Рисунок 1.3 - Модель генеративно-змагальної нейронної мережі [21].

На даний момент однією з останніх моделей, розроблених для вирішення завдання збільшення дозволу зображення за допомогою ІНС, є SRGAN (SuperResolution Generative Adversarial Network).

1.5.7 Мережа Хопфілда

Повно зв'язна нейронна мережа із симетричною матрицею зв'язків. В процесі роботи динаміка таких мереж сходиться до одного з положень рівноваги. Ці положення рівноваги визначаються заздалегідь в процесі навчання, вони є локальними мінімумами функціонала, званого енергією мережі (в найпростішому випадку - локальними мінімумами негативно певної квадратичної форми на n -вимірному кубі).

Така мережа може бути використана як автоасоціативна пам'ять, як фільтр, а також для вирішення деяких завдань оптимізації. На відміну від багатьох нейронних мереж, що працюють до отримання відповіді через певну кількість тактів, мережі Хопфілда працюють до досягнення рівноваги, коли

наступний стан мережі в точності дорівнює попередньому: початковий стан є вхідним чином, а при рівновазі отримують вихідний образ [23]. Мережа Хопфілда зображена на рисунку 1.4.

Мережа Хопфілда одношарова і складається з N штучних нейронів. Кожен нейрон системи може приймати на вході і на виході одне з двох станів (що аналогічно виходу нейрона з пороговою функцією активації).

Мережа складається з довільного числа шарів. Розрізняють вхідний шар - на який надходить вектор (зазвичай він не враховується у підрахунку шарів), вихідного шару, який видає результат розрахунків мережі і прихованих шарів. Вхідний шар не виконує ніяких обчислень - він просто розподіляє вектор на наступний шар і служить приймачем інформації. Зазвичай, якщо прихованих шарів більше, ніж два, то у всіх прихованих шарах однакову кількість нейронів.




Рисунок 1.4 - Структурна схема мережі Хопфілда

1.5.8 Нейронні мережі LSTM та GRU

Мережі LSTM і GRU позбавлені недозображень мереж Джордана і Елмана і здатні встановлювати кореляцію так само між віддаленими одна від одної об'єктами. Обумовлено це більш складною архітектурою і наявністю додаткових шарів. Архітектура LSTM представлена на рисунку 1.5. Довга короткострокова пам'ять - різновид архітектури рекурентних нейронних мереж, запропонована в 1997 році Сеппі Хохрайтером і Юргеном Шмідхубер. Як і більшість рекурентних нейронних мереж, LSTM-мережа є універсальною в тому сенсі, що при достатній кількості елементів мережі вона може виконати будь-яке обчислення, на яке здатний звичайний комп'ютер, для чого необхідна відповідна матриця ваг, яка може розглядатися як програма. На відміну від традиційних рекурентних нейронних мереж, LSTM-мережу добре пристосовано до навчання на задачах класифікації, обробки і прогнозування часових рядів у випадках, коли важливі події розділені часовими лагами з невизначеною тривалістю і кордонами. Відносна несприйнятливність до тривалості тимчасових розривів дає LSTM перевага по відношенню до альтернативних рекурентним нейронних мереж, прихованим марковським моделям і іншим методам навчання для послідовностей в різних сферах застосування [23]. Структура мережі LSTM зображена на рисунку 1.5.

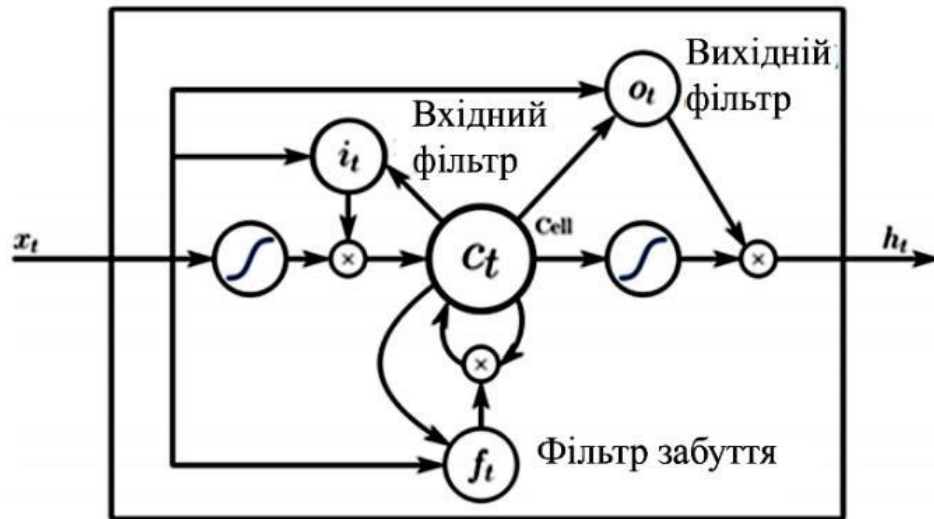


Рисунок 1.6 - Структура мережі LSTM

Мережа GRU відрізняється невеликою зміною зв'язку і відсутністю вихідного фільтра, що знижує кількість обчислення і параметрів, необхідних для роботи мережі. Однак це не позначається на точності роботи мережі [24].

1.5.9 Мережі Джордана і Елма

Мережі Джордана і Елмана є модифікацією багатошарової повномережі, отриманих за допомогою додавання шару контексту в топологію.

Однак, відрізняються вони тим, що в мережі Елмана шар контексту пов'язаний з прихованим шаром [25], а в мережі Джордана шар контексту пов'язаний з вихідним шаром [26]. Мережі даного типу можна побачити на рисунку 1.6.




Рисунок 1.6 - Мережа Джордана

Однак, якщо затримка між значущими подіями стає великою, то мережі даного типу можуть працювати некоректно.

1.5.10 Самоорганізаційна карта Кохонена

Нейронна мережа з навчанням без учителя, що виконує завдання візуалізації і кластеризації. Само організована карта складається з компонентів, які називаються вузлами або нейронами. Їх кількість задається аналітиком. Кожен з вузлів описується двома векторами. Перший - т. Зв. вектор ваги m , що має таку ж розмірність, що і вхідні дані. Другий - вектор r , що представляє собою координати вузла на карті.

Карта Кохонена візуально відображається за допомогою осередків прямокутної або шестикутної форми; остання застосовується частіше, оскільки в цьому випадку відстані між центрами суміжних осередків однакові, що підвищує коректність візуалізації карти. Топологія самоорганізується карти Кохонена зображена на рисунку 1.7.




Рисунок 1.7 - Само організаційна карта Кохонена

Спочатку відома розмірність вхідних даних, по ній певним чином будується початковий варіант карти. В процесі навчання вектори ваги вузлів наближаються до вхідних даних. Для кожного спостереження (семпли) вибирається найбільш схожий по вектору ваги вузол, і значення його вектора ваги наближається до спостереження. Також до спостереження наближаються вектори ваги декількох вузлів, розташованих поруч, таким чином якщо в безлічі вхідних даних два спостереження були схожі, на карті їм будуть відповідати близькі вузли. Циклічний процес навчання, перебираючи вхідні дані, закінчується після досягнення картою допустимої (заздалегідь заданій аналітиком) похибки, або після здійснення заданої кількості ітерацій.

Таким чином, в результаті навчання карта Кохонена класифікує вхідні дані на кластери і візуально відображає багатовимірні вхідні дані в двовимірній площині, розподіляючи вектори близьких ознак в сусідні осередки і розфарбовуючи їх в залежності від аналізованих параметрів нейронів [27].

1.5.11 Мережа Хеммінга

Нейронна мережа Хеммінга - вид нейронної мережі, що використовується для класифікації бінарних векторів, основним критерієм в якій є відстань Хеммінга. Є розвитком нейронної мережі Хопфілда. Структура мережі Хеммінга зображена на рисунку 1.8.

Мережа Хеммінга - тришарова нейронна мережа зі зворотним зв'язком. Кількість нейронів у другому і третьому шарах дорівнює кількості класів класифікації.

Синапси нейронів другого шару з'єднані з кожним входом мережі, нейрони третього шару пов'язані між собою негативними зв'язками, крім синапсу, пов'язаного з власним аксоном кожного нейрона - він має позитивний зворотний зв'язок [28].

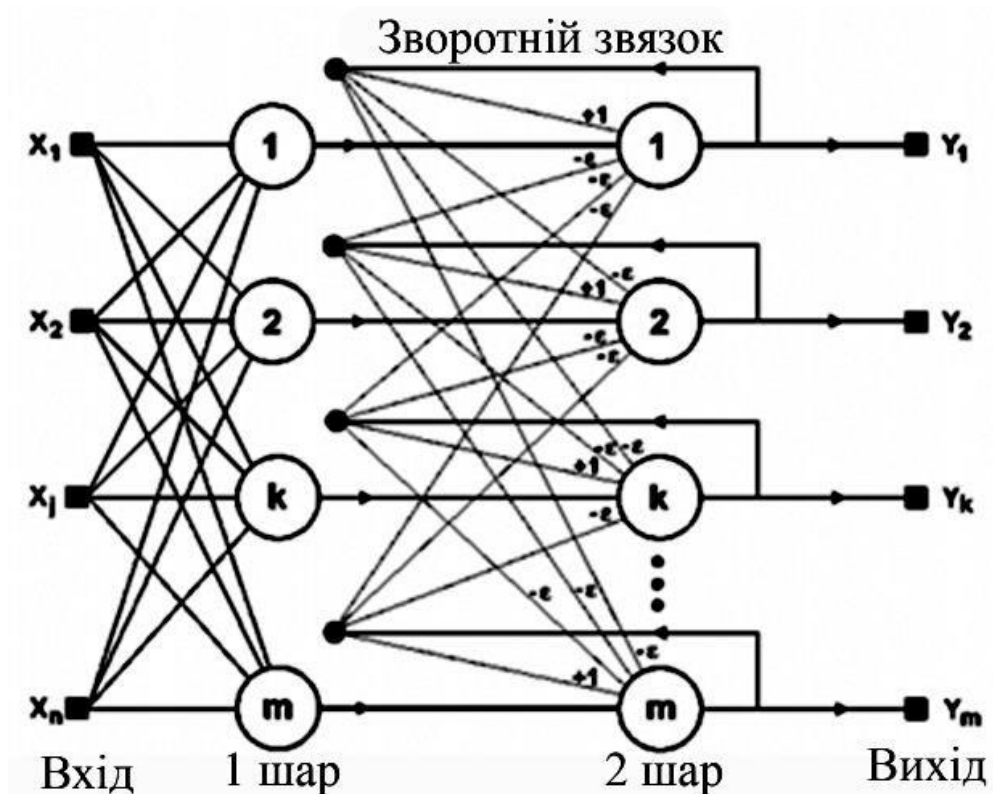


Рисунок 1.8 - Мережа Хеммінга

1.6 Класифікація нейромереж

У цій магістерській дисертації буде розглянуто напрямок генерування зображень на основі генеративно-змагальних нейронних мереж. Було описано методологію навчання генеративних змагальних мереж. Ключова ідея полягає в тому, щоб розвивати як генератор, так і дискримінатор поступово: починаючи з низької роздільної здатності додаємо нові шари, які моделюють все більш тонкі деталі навчання прогресує. Це одночасно прискорює тренування і значно стабілізує його, дозволяючи нам створювати зображення безпрецедентної якості, наприклад, зображення CELEBA.

Поставлена задача навчити генеративно-змагальну нейронну мережу налаштовувати мережеву архітектуру та ваги зв'язків для ефективного виконання різних завдань. Нейронна мережа повинна регулювати ваги зв'язку відповідно до наявного зразка тренувань. Функціонування мережі покращується в міру ітеративного регулювання ваг. Здатність мережі вчитися на прикладах робить їх більш привабливими порівняно із системами, які слідують певній системі правил роботи, сформульованій експертами.

Існують два концептуальних підходи до навчання нейронних мереж: навчання з вчителем і навчання без вчителя.

Навчання нейронної мережі з викладачем означає, що для кожного вхідного вектора навчального набору існує необхідне значення вихідного вектора, що називається цільовим. Ці вектори утворюють тренувальну пару. Ваги мережі змінюються до тих пір, поки не буде прийнятний рівень відхилення вихідного вектора від цілі для кожного вхідного вектора.

Навчання без вчителя має дещо інший характер і зустрічається рідше. За такого сценарію нейронна мережа не отримує бажаного результату. Ця підготовка підходить для мереж, які мають завдання кластеризації даних за заданими параметрами. Тобто, проаналізувавши велику кількість вхідних даних, мережа поділяє їх на категорії за певними характеристиками.

Підсилення підготовки використовується, коли можна оцінити чистий результат, отриманий мережею.

Тобто, заохочуючи нейронну мережу щоразу, коли результат буде максимально наближений до бажаного, буде дозволено їй шукати будь-яке рішення проблеми до тих пір, поки воно дасть бажані результати.

Для проектування процесу навчання потрібно мати модель середовища, в якій працює нейронна мережа - знати інформацію, доступну для мережі. Вам також потрібно визначити, як змінювати вагу мережі - які правила навчання регулюють процес налаштування. Алгоритм тренування означає процедуру, яка використовує правила тренування для регулювання ваги.

Найважливішою особливістю нейронних мереж є їх здатність вчитися на даних про навколишнє середовище і, як результат, підвищувати свою продуктивність. Продуктивність збільшується з часом відповідно до певних правил. Тренування нейронної мережі здійснюється за допомогою інтерактивного процесу коригування синаптичних ваг і порогів. В ідеалі нейронна мережа отримує знання про навколишнє середовище при кожній ітерації навчального процесу.

Багато понять пов'язані з поняттям навчання, тому важко дати чітке визначення цьому процесу. Більше того, від цього залежить процес навчання. Це робить практично неможливим чітке визначення цього поняття. Наприклад, процес навчання з точки зору психолога принципово відрізняється від того, який має вчитель школи. З точки зору нейронної мережі, ймовірно, можна використовувати таке визначення.

Навчання - це процес, в якому налаштування вільних нейронних мереж налаштовуються за допомогою моделювання середовища, в яке вбудована ця мережа. Тип тренінгу визначається тим, як ці параметри коригуються.

Це визначення процесу навчання нейронної мережі передбачає таку послідовність подій:

- стимулюючи нейронну мережу, отримує подразники із зовнішнього середовища;

– внаслідок реалізації першого абзацу вільні параметри змінюються; – після зміни внутрішньої структури нейронна мережа відповідає штрафів вже іншим чином.

Наведений вище перелік чітких правил вирішення проблеми навчання нейронної мережі називається алгоритмом навчання. Не існує універсального алгоритму навчання, який би підходив для всіх архітектур нейронної мережі. Існує лише набір інструментів, представлених багатьма алгоритмами навчання, кожен з яких має свої переваги. Алгоритми навчання відрізняються один від одного способом коригування ваги синаптичних нейронів. Ще однією чудовою особливістю є спосіб навчання нейронної мережі для з'єднання із зовнішнім світом. У цьому контексті вони говорять про парадигму навчання, пов'язану з моделлю середовища, в якій діє ця нейронна мережа.

Такий підхід до терміна "навчання нейронних мереж" узгоджується з біологічними нейронними мережами. Наш мозок складається з величезної кількості підключених нейронних мереж. Кожен складається з однотипних нейронів (функція активації однакова). Дізналися, змінюючи синапси - елементи, що підсилюють / послаблюють вхідний сигнал.

Однак є ще один важливий момент. Якщо ви тренуєте мережу, використовуючи лише один вхідний сигнал, мережа просто "запам'ятовує правильну відповідь". Ззовні, здавалося б, вона дуже швидко «навчилася». І як тільки ви подасте трохи змінений сигнал, чекаючи, щоб побачити правильну відповідь, мережа видасть нісенітницю.

Насправді, для чого нам потрібна мережа, яка визначає обличчя лише на одній фотографії. Було очікувано, що мережа зможе узагальнити деякі функції та розпізнати обличчя і на інших фотографіях.

Навчання нейронної мережі з учителем припускає, що для кожного вхідного вектора з навчальної множини існує необхідне значення вихідного вектора, званого цільовим.

Навчання нейронної мережі без вчителя є набагато більш правдоподібною моделлю навчання з точки зору біологічних коренів штучних нейронних мереж.

При змішаному навчанні частина ваг визначається за допомогою навчання з учителем, у той час як інша виходить за допомогою самонавчання.

Різні алгоритми навчання та пов'язані з ними архітектури мереж представлені у таблиці 1.1. В останній колонці перераховані задачі, для яких можуть бути застосовані різні алгоритми. Кожен з алгоритмів навчання орієнтований на мережу певної архітектури і призначений для обмеженого класу задач.

Таблиця 1.1 — Відомі алгоритми навчання нейронних мереж

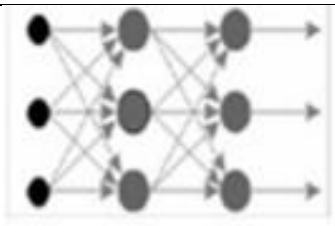
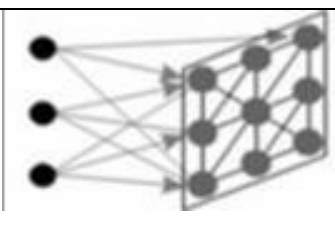
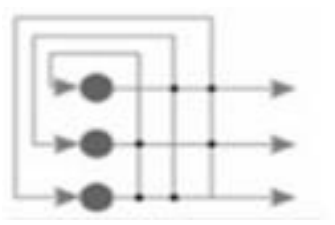
Типи навчання	Правило навчання	Архітектура	Алгоритм навчання	Задача
З вчителем	Корекція помилки	Одношаровий та багатошаровий перцептрон	Алгоритми навчання перцептрона Зворотне поширення	Класифікація образів, Аппроксимація функцій, Передбачення, управління
	Больцман	Рекурентна	Алгоритм навчання Больцмана	Класифікація образів
	Хебб	Багатошарова прямого розповсюдження	Лінійний дискримінантний аналіз	Аналіз даних, Класифікація образів
	Змагальні	Змагальня	Векторне квантування	Категоризація всередині класу, Аналіз даних
		Мережа ART	ARTMap	Класифікація образів

Продовження таблиці 1.1

Без вчителя	Корекція помилки	Багатошарова прямого розповсюдження	Проекція Саммона	Категоризація всередині класу, Аналіз даних
	Хебб	Прямого поширення або змагання	Аналіз головних компонентів	Аналіз даних, Стиснення даних
		Мережа Хапфілда	Навчання асоціативної пам'яті	Асоціативна пам'ять
	Змагальні	Змагальна	Векторне квантування	Категоризація, Стиснення даних
		Мережа Кохена	SOM Кохонена	Категоризація, Аналіз даних
		Мережа ART	ART1, ART2	Категоризація
Змішані	Корекція помилки та змагання	Мережа RBF	Алгоритм навчання RBF	Класифікація образів, Апроксимація функцій, Передбачення, Управління

ШНМ добре підходять для розпізнавання образів і вирішення задач класифікації, оптимізації і прогнозування. Зростання обсягів баз даних в техніці, бізнесі, медицині, екології і зростання вимог до точності рішення ставлять нові вимоги перед нейронними мережами. В таблиці 1.2 приведені типи ШНМ та класи задач, які вони вирішують.

Таблиця 1.2 – Типи штучних мереж

Типи ШНМ	Архітектура ШНМ	Клас задач які вирішує ШНМ
Багатошаровий перцептрон		Апроксимація функцій, класифікація
Само організаційна карта Кохонена		Стиснення даних, виділення признаков
Мережа Хапфілда		Асоціативна пам'ять, кластеризація даних

Одним із завдань, яку повинна виконувати система машинного бачення, є розпізнавання. Після оцінки різних властивостей об'єкта, наприклад відбивної здатності поверхні або кольору, система повинна мати у своєму розпорядженні деякою схемою, на підставі якої об'єкт буде віднесений до одного з відомих класів. Класифікація образів забезпечує кошти для вирішення цього завдання. Основною ідеєю є виділення характеристик або ознак. Величин, які можуть виявитися корисними при розрізненні елементів різних класів. Значення окремих ознак потім об'єднуються і утворюють вектор ознак. Таким чином, інформація, отримана на основі зображення об'єкта, використовується для ідентифікації точки в деякому багатовимірному просторі.

Кластеризація (або кластерний аналіз) - це задача розбиття множини об'єктів на групи, які називаються кластерами. Усередині кожної групи повинні виявитися «схожі» об'єкти, а об'єкти різних групи повинні бути якомога більш відмінні. Головна відмінність кластеризації від класифікації полягає в тому, що перелік груп чітко не заданий і визначається в процесі роботи алгоритму.

Апроксимація дозволяє досліджувати числові характеристики і якісні властивості об'єкта, зводячи завдання до вивчення більш простих або більш зручних об'єктів (наприклад, таких, характеристики яких легко обчислюються або властивості яких вже відомі). У теорії чисел вивчаються діофантови наближення, зокрема, наближення ірраціональних чисел раціональними. В геометрії розглядаються апроксимації кривих ламаними. Деякі розділи математики по суті цілком присвячені апроксимації, наприклад, теорія наближення функцій, чисельні методи аналізу.

Основне завдання апроксимації - побудова наближеної (апроксимуючої) функції, в цілому найближче проходить близько даних точок або близько цієї безперервної функції. Таке завдання виникає при наявності похибки у вихідних даних (в цьому випадку недоцільно проводити функцію точно через всі крапки, як в інтерполяції) або при бажанні отримати спрощене математичний опис складної або невідомої залежності.

Для початку потрібно скласти вектор характеристик для кожного об'єкта - як правило, це набір числових значень, наприклад, зростання-вага людини. Однак існують також алгоритми, що працюють з якісними (категорійними) характеристиками. Після того, як було визначено вектор характеристик, можна провести нормалізацію, щоб всі компоненти давали однаковий внесок при розрахунку «відстані».

У разі якщо апроксимація проводиться на безперервному безлічі точок (відрізку), апроксимація називається безперервної або інтегральної. Прикладом такої апроксимації може служити розкладання функції в ряд Тейлора, тобто заміна деякої функції статечним многочленом.

Найбільш часто зустрічають видом точкової апроксимації є інтерполяція - знаходження проміжних значень величини за наявним дискретному набору відомих значень.

Пам'ять, що адресується за змістом. У моделі обчислень фон Неймана звертання до пам'яті доступно тільки за допомогою адреси, який не залежить від утримання пам'яті. Більш того, якщо допущена помилка в обчисленні адреси, то може бути знайдена зовсім інша інформація. Асоціативна пам'ять, чи пам'ять, що адресується за змістом, доступна за вказівкою заданого змісту. Зміст пам'яті може бути викликаний навіть по частковому входу. Асоціативна пам'ять надзвичайно ефективна при створенні мультимедійних інформаційних баз даних.

Пам'ять нейронної мережі є відмово стійкої. При видаленні окремих частин нейронної мережі відбувається лише зниження якості інформації, в ній зберігається, але не повне її зникнення. Це відбувається тому, що інформація зберігається в розподіленій формі.

Програмні продукти на базі нейронних мереж використовують для контролю якості води та можуть знаходити пластикові бомби в багажі авіапасажирів. Фахівці інвестиційного банку за допомогою програмного нейро-пакета роблять короткострокові прогнози коливань курсів валют. Проведення аналізу вирішення завдань на нейронних мережах дозволяє виділити основні переваги їх використання: Рішення завдань при невідомих закономірностях. Використовуючи здатність навчання на безлічі прикладів, нейронна мережа здатна вирішувати завдання, в яких невідомі закономірності розвитку ситуації і залежності між вхідними і вихідними даними. Традиційні математичні методи та експертні системи в таких випадках не використовують. Нейронні мережі дозволяють виконувати екстраполяцію і інтерполяцію на основі інформації, що зберігається в них. Тобто, навчання дозволяє надати мережі здатності здійснювати пошук важливих особливостей або зв'язків в даних. Після цього мережа в стані екстраполувати і виявляти зв'язки в нових даних, що до неї надходять. Наприклад, в одному експерименті

було проведено навчання нейронної мережі на гіпотетичному прикладі. Після закінчення навчання мережу придбала здатність адекватно реагувати на питання, за якими навчання не проводилося. Для отримання нейронної мережі, що використовується для оцінки якісних характеристик проєктованих інформаційних систем, найбільш придатною є парадигма навчання з учителем. Такий підхід дозволяє врахувати думку експертів з проєктування і впровадження інформаційних рішень, а також дані про реальні проєкти, зібрані при їх аналізі.

1.7 Висновки до першого розділу

ГЗМ-канали забезпечують потужну основу для створення природних зображень із високою якістю сприйняття. Процедура ГЗМ заохочує реконструкції рухатись до областей простору пошуку з високою ймовірністю містити фотореалістичні зображення і, отже, ближче до природного колектора зображень, як показано на малюнку 3. У цій роботі ми описуємо першу дуже глибоку архітектуру ResNet [29, 30] з використанням концепції ГЗМ для формування функції сприйняття втрат для фотореалістичного СРЗОЗ. Наші основні внески:

- Ми встановили новий рівень техніки для зображення ВРЗ із високими коефіцієнтами збільшення (4x), виміряними ПВСШ та структурною схожістю (ІСП), за допомогою наших 16 блоків глибинного ResNet (SRResNet), оптимізованих для СКП.

- Пропонується використання СРГЗМ - мережу на базі генеративних змагальних мереж, оптимізовану для нових сприйнятливих втрат. Тут ми замінюємо втрату вмісту на основі СКП втрат, розрахованою на картах характеристик дуже глибоких згорткових мереж для

широкомасштабного розпізнавання зображень, які є більш інваріантними до змін у піксельному просторі.

Великим тестом на зображеннях із трьох загальнодоступних наборів даних підтверджено, що СРГЗМ - це новий підхід з великим відривом для оцінки фотореалістичних зображень СРЗ із високими коефіцієнтами збільшення (4x).

РОЗДІЛ 2 СТРУКТУРА ТА МЕТОДИ ГЕНЕРАТИВНО- ЗМАГАЛЬНИХ НЕЙРОМЕРЕЖ

2.1 Вступ

У SISR метою є оцінка зображення I^{SR} із високою роздільною здатністю із супер-роздільною здатністю із вхідного зображення I^{LR} із низькою роздільною здатністю. Тут I^{LR} - це версія з низькою роздільною здатністю аналога з високою роздільною здатністю I^{HR} . Зображення з високою роздільною здатністю доступні лише під час тренувань. На тренуванні I^{LR} отримують, застосовуючи гауссовий фільтр до I^{HR} , після чого операція зниження вибірки з коефіцієнтом зниження вибірки r . Для зображення з кольоровими каналами C ми описуємо I^{LR} дійсним тензором розміром $W \times H \times C$ та I^{HR} , I^{SR} на $rW \times rH \times C$ відповідно.

Наша кінцева мета - навчити генеруючу функцію G , яка оцінює для даного вхідного зображення LR відповідний аналог HR. Щоб досягти цього, ми навчаємо генераторну мережу як ЗНМ G_{θ_G} , що параметризується θ_G . Тут $\theta_G = \{W1: L; b1: L\}$ позначає ваги та упередження глибинної мережі L -шару і отримується оптимізацією специфічної для SR функції втрат I^{SR} . Для тренувань зображень беремо:

$$\hat{\theta}_G = \arg \min_{\theta_G} \frac{1}{N} \sum_{n=1}^N l^{SR}(G_{\theta_G}(I_n^{LR}), I_n^{HR}) \quad (1)$$

де, I_n^{HR} , $n = 1, \dots, N$ та I_n^{LR} , $n = 1, \dots, N$

У цій роботі було розроблено перцептивні втрати I^{SR} як зважену комбінацію декількох компонентів втрат, які моделюють різні бажані

характеристики відновленого СРЗ-зображення. Індивідуальні функції збитків більш докладно описані в розділі функція сприйняття втрат.

2.2 Генеративно-змагальні нейронні мережі

2.2.1 Архітектура

Слідом за Гудфеллоу та ін. [30] була визначена дискримінаційна мережа D_{θ_D} , яку оптимізували поперемінно разом із G_{θ_G} для вирішення проблеми мін-макс.

$$\min_{\theta_G} \max_{\theta_D} \mathbb{E}_{I^{HR} \sim p_{\text{train}}(I^{HR})} [\log D_{\theta_D}(I^{HR})] + \mathbb{E}_{I^{LR} \sim p_G(I^{LR})} [\log(1 - D_{\theta_D}(G_{\theta_G}(I^{LR})))] \quad (2)$$

Загальна ідея, що стоїть за цією формулою, полягає в тому, що вона дозволяє тренувати генеративну модель G з метою обдурити диференційований дискримінатор D , який навчений розрізняти суперрозрішені зображення від реальних зображень. За допомогою цього підходу вказаний генератор може навчитися створювати рішення, які дуже схожі на реальні зображення, і тому їх важко класифікувати за допомогою дискримінатора D . Це заохочує перцептивно чудові рішення, що перебувають у підпросторі, у різноманітті природних зображень. Це на відміну від рішень СРЗ, отриманих шляхом мінімізації вимірювань похибки в пікселях, таких як СКП.

В основі дуже глибокої генераторної мережі G , яка проілюстрована на малюнку 2.1.1, лежать залишкові блоки B з однаковим розташуванням. Орієнтуючись на працю Джонсона [31] у даній роботі був використаний макет

блоку, запропонований Гроссом та Вільбером [32]. Зокрема, були використані два згорткові шари з невеликими ядрами 3×3 і 64 картами функцій, за якими слідують рівні нормалізації партії та параметрична ReLU як функція активації. Була збільшена роздільна здатність вхідного зображення за допомогою двох навчених шарів згортки субпікселів, як запропонував у своїй праці Ши.

Для розрізнення реальних зображень ВРЗ із згенерованих зразків зображень СРЗ була навчена дискримінаційна мережа. Архітектура показана на малюнку 2.1.1. Дотримані архітектурні рекомендації, узагальнені Редфордом та використана активаційна функція нещільна ReLU ($\alpha = 0,2$). Також вдалося уникнути максимального об'єднання в мережі. Мережа дискримінатора навчена вирішувати задачу максимізації у рівнянні 2. Вона містить вісім згорткових шарів із зростаючою кількістю 3×3 ядер фільтра, збільшуючись у 2 рази з 64 до 512 ядер, як у мережі ЗМШР. Поступова згортка використовується для зменшення роздільної здатності зображення кожного разу, коли кількість функцій подвоюється. Отримані 512 карт функцій супроводжуються двома щільними шарами та остаточною функцією активації сигмоїдної системи, щоб отримати ймовірність класифікації зразків.

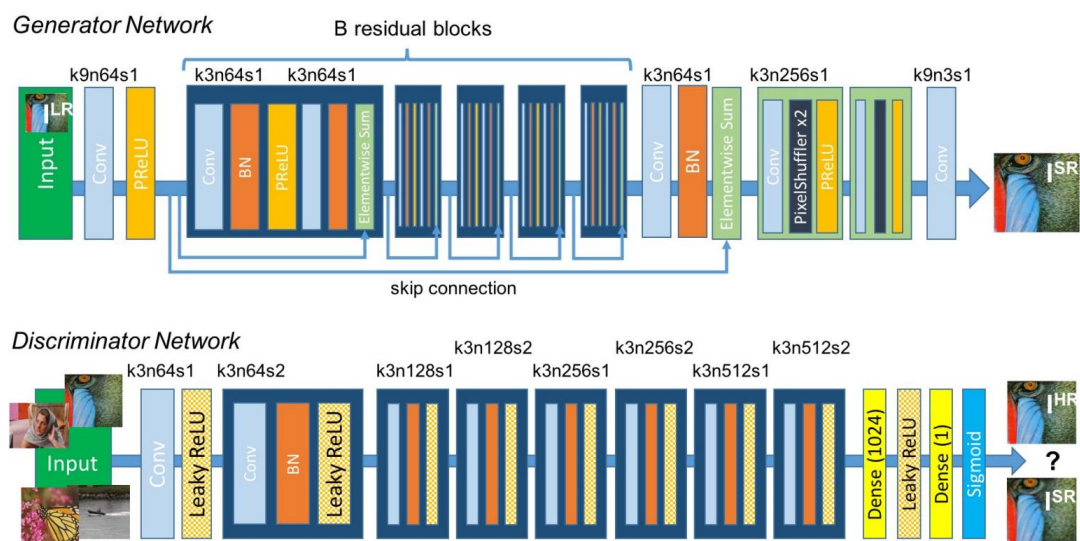


Рисунок 2.1.1: Архітектура мережі генераторів та дискримінаторів з відповідним розміром ядра, кількістю карт функцій та кроком, вказані для кожного згорткового шару

2.2.2 Генератор

Генеративні алгоритми зайняті зворотним. Замість того, щоб передбачати категорію за наявними образами, вони намагаються підібрати образи до даної категорії.

Генеративна мережу накладає шум на зображення (використовую вектор шуму) і виводить його. Під час тренування генеративна мережа вивчає, які області зображення необхідно змінити або поліпшити, щоб дискримінатори знадобилося більше часу для визначення автентичності згенерованого зображення.

Генеративних мережу з кожним разом виробляє зображення, яке все більше схоже на реальне, в той час як дискримінативна мережа намагається знайти відмінності між реальним і штучним зображенням. Головна мета - зробити таку генеративну мережу, яка зможе відтворювати відрізнити від реальних зображення.

У той час як дискримінаційні алгоритми хвилює взаємозв'язок між y і x , генеративні алгоритми хвилює "звідки беруться x ". Вони дозволяють знаходити $p(x | y)$, ймовірність x при даному y або ймовірність образів при даному класі (генеративні алгоритми також можуть використовуватися в якості класифікаторів. Вони можуть робити більше, ніж класифікувати вхідні дані.).

Ще одне уявлення про роботу генеративних алгоритмів можна отримати, розділяючи дискримінаційні моделі від генеративних таким чином:

- дискримінаційні моделі вивчають кордон між класами;
- генеративні моделі моделюють розподіл окремих класів.

2.2.3 Дискримінатор

Дискримінаційні алгоритми намагаються класифікувати вхідні дані. З огляду на особливості отриманих даних, вони намагаються визначити категорію, до якої вони належать.

Наприклад, пробігаючи всі слова в листі дискримінаційний алгоритм може передбачити, є повідомлення спамом або не спам. Спам - це категорія, а пакет слів, зібраний з електронної пошти - образи, які становлять вхідні дані. Математично категорії позначають y , а образи позначають x . Запис $p(y | x)$ використовується для позначення «ймовірності y при заданому x », яка позначає «ймовірність того, що електронний лист є спамом при наявному наборі слів». Мережа дискримінаторів є стандартною згортковою мережею, яка може класифікувати зображення, що подаються на неї за допомогою біноміального класифікатора, що розпізнає зображення як реальні або як підроблені. Генератор в певному сенсі є зворотний сверточное мережу: хоча стандартний згортковий класифікатор приймає зображення і зменшує його дозвіл, щоб отримати можливість, генератор приймає вектор випадкового шуму і перетворює його в зображення.

Отже, дискримінаційні функції зіставляють образи з категорією. Вони зайняті тільки цієї кореляцією.

2.2.4 Функція сприйняття втрат

Визначення функції сприймання втрат l_{SR} є критичним для роботи мережі генераторів. Хоча l_{SR} зазвичай моделюється на основі СКП [33], дана система була вдосконалена на основі праць Джонсона [33] та Бруно та була розроблена функція збитків, яка оцінює рішення з огляду на релевантні

характеристики. Сформульована перцептивна втрата як зважена сума втрати вмісту ($l_{SR X}$) та компонента змагальних втрат як:

$$l^{SR} = \underbrace{l_X^{SR}}_{\text{content loss}} + \underbrace{10^{-3} l_{Gen}^{SR}}_{\text{adversarial loss}} \quad (3)$$

perceptual loss (for VGG based content losses)

Далі описані можливі варіанти втрати вмісту $l_{SR X}$ та змагальних втрат $l_{SR Gen}$.

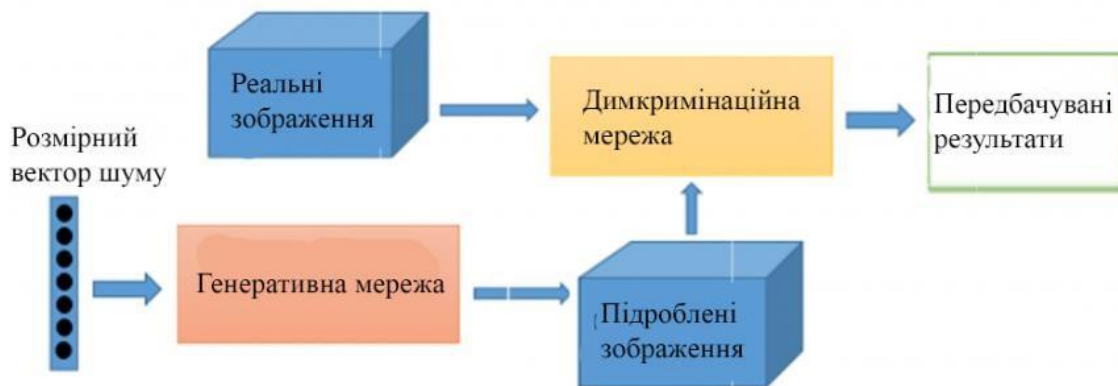


Рисунок 2.1 - Алгоритм роботи генеративно-змагальної нейронної мережі

Ви можете уявити GAN як фальшивомонетника і поліцейського, що грають в кішки мишки, де фальсифікатор вчиться виготовляти неправдиві купюри, а поліцейський вчиться їх виявляти. Обидва динамічні. поліцейський теж тренується (можливо, центральний банк відзначає пропущені купюри), і кожна сторона приходить до вивчення методів іншого в постійній ескалації.

Мережа дискримінаторів є стандартною згортковою мережею, яка може класифікувати зображення, що подаються на неї за допомогою біноміального класифікатора, що розпізнає зображення як реальні або як підроблені.

Генератор в певному сенсі є зворотний сверточное мережу (рис 2.2): хоча стандартний згортковий класифікатор приймає зображення і зменшує його дозвіл, щоб отримати можливість, генератор приймає вектор випадкового шуму і перетворює його в зображення. Перший відсіває дані за допомогою методів зниження дискретизації, таких як maxpooling, а другий генерує нові дані.




Рисунок 2.2 - Алгоритм роботи на основі генератора та дискримінатора

Обидві мережі намагаються оптимізувати цільову функцію або функцію втрат в грі zero-sum. Це, по суті, модель актора-критика (actor-critic). Коли дискриміратор змінює свою поведінку, то і генератор змінює, і навпаки.

2.2.5 Робота автокодерів

Корисно порівняти генеративні змагальні мережі з іншими нейронними мережами, такими як автокодери (автоенкодери) і варіаційні автокодери.

Автокодери кодують вхідні дані в вектори. Вони створюють приховане або стислий уявлення необроблених даних. Вони корисні при зменшенні розмірності: вектор, службовець в якості прихованого уявлення, стискає необроблені дані в меншу кількість. Автокодери (рис 2.3) можуть бути

пов'язані з так званим декодером, який дозволяє відновлювати вхідні дані на основі їх прихованого уявлення, як і у випадку з машиною Больцмана.




Рисунок 2.3 - Алгоритм роботи автокодерів

Варіаційні автокодери є генеративним алгоритмом, який додає додаткове обмеження для кодування вхідних даних, а саме те, що приховані уявлення нормалізуються. Варіаційні автокодери здатні стискати дані як автокодери і синтезувати дані подібно GAN. Однак, в той час як GAN генерують дані деталізовано, зображення, створені VAE, бувають більш розмитими. Приклади DeepLearning4j включають в себе як автокодери, так і варіаційні автокодери.

Ви можете розділити генеративні алгоритми на три типи, які маючи:

- категорію, проорокують пов'язані функції (Naive Bayes);
- приховане уявлення, проорокують пов'язані функції (VAE, GAN);
- деякі образи, проорокують інше (inpainting, imputation).

2.2.6 Втрата вмісту

Втрати СКП в пікселях розраховуються як:

$$l_{MSE}^{SR} = \frac{1}{r^2 W H} \sum_{x=1}^{rW} \sum_{y=1}^{rH} (I_{x,y}^{HR} - G_{\theta_G}(I^{LR})_{x,y})^2 \quad (4)$$

Це найбільш широко використовувана ціль оптимізації для зображень з СРЗ, на яку покладаються багато сучасних підходів. Однак, досягаючи особливо високого ПВСШ, рішенням задач оптимізації СКП часто не вистачає високочастотного вмісту, що призводить до сприйняття рішень із надмірно гладкими текстурами.

Замість того, щоб покладатися на піксельні втрати, у даній роботі використовуються ідеї Гатіс, Бруно та Джонсона [34] і використовується функцію втрат, яка ближча до перцептивної подібності. Втрата ЗМШР визначена на основі шарів активації ReLU попередньо навченої 19-шарової мережі ЗМШР, описаної у праці Симоняна. За допомогою фі, j вказується карта особливостей, отримана j-м згорткою (після активації) перед i-м шаром максимального сполучення в мережі ЗМШР19. Потім визначається втрата ЗМШР як евклідова відстань між репрезентаціями реконструйованого зображення $G_{\theta_G}(I^{LR})$ та еталонним зображенням I ВРЗ:

$$l_{VGG/i,j}^{SR} = \frac{1}{W_{i,j} H_{i,j}} \sum_{x=1}^{W_{i,j}} \sum_{y=1}^{H_{i,j}} (\phi_{i,j}(I^{HR})_{x,y} - \phi_{i,j}(G_{\theta_G}(I^{LR}))_{x,y})^2 \quad (5)$$

де, $W_{i,j}$ та $H_{i,j}$ описують розміри відповідних карт функцій у мережі ЗМШР.

2.2.7 Змагальний збиток

На додаток до описаних дотепер втрат вмісту, також додана генеративна складова ГЗМ до перцептивних втрат. Це спонукає мережу віддавати перевагу рішенням, що містяться у різноманітні природних зображень, намагаючись обдурити дискримінаційну мережу. Генеративні втрати l^{SR}_{Gen} визначаються на основі ймовірностей дискримінатора $D_{\theta_D}(G_{\theta_G}(I^{LR}))$ для всіх навчальних зразків як:

$$l^{SR}_{Gen} = \sum_{n=1}^N -\log D_{\theta_D}(G_{\theta_G}(I^{LR})) \quad (6)$$

де, $D_{\theta_D}(G_{\theta_G}(I^{LR}))$ - це ймовірність того, що реконструйоване зображення $G_{\theta_G}(I^{LR})$ є природним ВРЗ-зображенням.

Для кращої поведінки градієнта проводимо мінімізацію $-\log D_{\theta_D}(G_{\theta_G}(I^{LR}))$ замість $\log [1 - D_{\theta_D}(G_{\theta_G}(I^{LR}))]$ [22].

2.2.8 Поради із навчання GAN

Коли ви тренуєте дискримінатор, утримуйте значення генератора постійними; і коли ви тренуєте генератор, утримуйте дискримінатор на одному рівні. Кожен повинен тренуватися проти статичного противника. Наприклад, генератору це дозволить краще зчитувати градієнт, за яким він повинен вчитися.

Точно так же попереднє тренування дискримінатора проти MNIST сприятиме встановленню більш чіткого градієнта.

Кожна частина GAN може здолати іншу. Якщо дискримінатор дуже хороший, він буде повертати значення дуже близькі до 0 або до 1, так що генератор буде зазнавати труднощів у читанні градієнта. Якщо генератор дуже хороший, він буде постійно використовувати недозображення дискримінатора, що призводять до неправильних негативів.

GAN вимагають багато часу на тренування. На одному GPU тренування може займати години, а на одному CPU - більше одного дня.

Незважаючи на складність настройки і, отже, використання, GAN стимулювали створення багатьох цікавих досліджень і статей, наприклад:

- PGGAN - прогресивна генеративна нейронна мережа від Nvidia;
- TwinGAN - междоменной перенесення людських портретів;
- XOGAN: перетворення одного зображення в кілька;
- метод відновлення очей за допомогою Exemplar GAN від Facebook AI Research.

2.3 Проблеми тренування

Генеративно-змагальні мережі сумно відомі своєю складністю в підготовці і нестабільністю роботи (рис 2.4). Одна з проблем полягає в тому, що якщо генератор занадто сильно випереджає дискримінатор в темпах навчання, то його вибірка зображень звужується до конкретно тих, які допомагають йому обдурити дискримінатор. Фактично, в результаті навчання генератора зводиться до створення одного-єдиного універсального зображення для обману дискримінатора. Ця проблема називається «режимом колапсу».



Рисунок 2.4 - Зображення згенеровані генеративно-змагальною нейронною мережею

Режим колапсу генеративно-змагальних мереж схожий на Goodfellow's. Зверніть увагу, багато хто з цих зображень спальні виглядають дуже схожими один на одного.

Інша проблема полягає в тому, що, коли генератор ефективно обманює дискримінатор оперує дуже маленьким градієнтом, тому не може отримати достатньо даних для знаходження істинного відповіді, при яких це зображення виглядало б більш реалістичним.

Зусилля дослідників щодо вирішення цих проблем в основному були спрямовані на зміну структури функції втрат. Одним з простих змін, запропонованих Xudong Mao et al., 2016, є заміна функції втрат на пару простих функцій, в основі яких лежать квадрати меншої площі. Це призводить до стабілізації процесу тренування, отриманню більш якісних зображень і меншому шансу колапсу з використанням незатухаючих градієнтів.

Інша проблема, з якою зіткнулися дослідники, - це складність отримання зображень з високою роздільною здатністю, почасти через те, що більш детальне зображення дає дискримінатори більше інформації для виявлення підроблених зображень. Сучасні генеративно-змагальні мережі починають навчати мережу з картинок в низькій роздільній здатності і поступово додають все більше і більше шарів, поки не буде досягнутий бажаний розмір зображення.

Поступове додавання шарів з більш високою роздільною здатністю під час навчання генеративно-змагальних мереж істотно підвищує стабільність усього процесу, а також швидкість і якість одержуваного зображення.

2.4 Як і де застосовується GAN і генеративні моделі

Створення контенту і даних: наприклад, створення картинок для інтернет-магазину, аватарів для ігор, відеокліпів, згенерованих автоматично, виходячи з музичного біта твору, або навіть віртуальних провідних для ТВпрограм. Завдяки роботі GAN і генеративних моделей виникає синтез даних, на яких потім будуть навчатися інші системи.

Автоматичне редагування: цей підхід вже використовується в сучасних смартфонах і деяких програмах. Він дозволяє змінювати на фотографії обличчя, кількість зморшок і зачіску, міняти день на ніч, старіють зображення і т.п.

Генерація приголомшливо реалістичних зображень "знаменитостей" (а насправді - неіснуючих людей) за допомогою PG GAN від nVidia (рис 2.5). С допомогою цієї мережі можна також генерувати зображення будь-яких інших категорій.



Рисунок 2.5 - Зображення згенерованих обличч знаменитостей

Всі ці зображення згенеровані системою на базі генеративно-змагальних нейронних мереж (рис 2.6), частина з них виглядає не дуже реалістично, але інша частина вельми правдоподібна.



Рисунок 2.6 - Зображення згенеровані ГЗМ

Модель Everybody Dance Now (рис 2.7), створена групою вчених з Університету Берклі, представляє простий метод на основі генеративних нейронних мереж передачі руху «зроби як». Дано: вихідне відео танцюючого людини. Досягнутий результат: інша людина була змушена танцювати на нашому зображенні. Це називається "перенесення руху".



Рисунок 2.7 - Кадр з відео прикладу роботи Everybody Dance Now

Перенесення стилю з одного зображення на інше дозволяє за допомогою неймереж робити такі вражаючі речі як "перетворити коня в зебру" (рис 2.8).



Рисунок 2.8 - Приклади підміни одного зображення на інше

Або генерувати "аніме-портрети" (рис 2.9) по фотографії. На цій картинці видно, як з цим завданням справляються різні види Ганов.

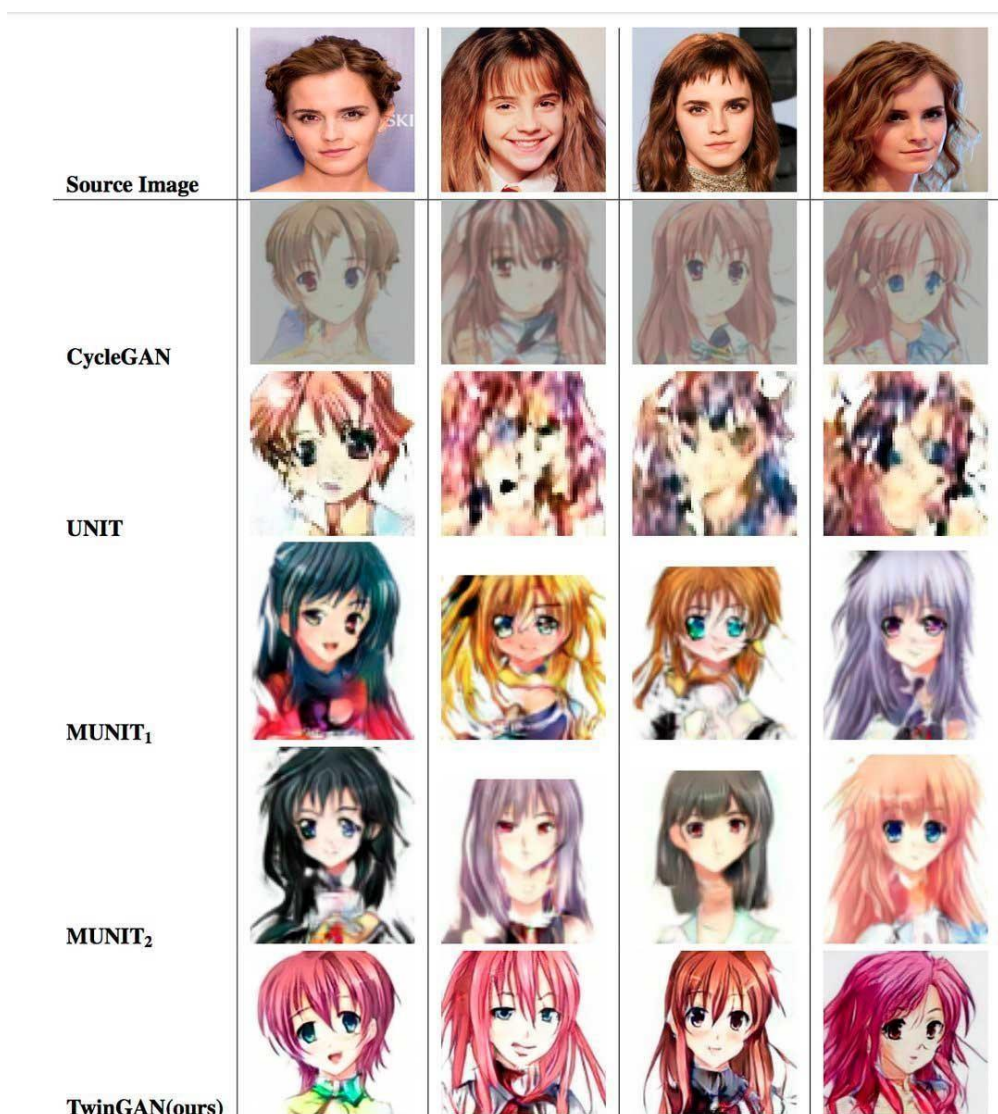


Рисунок 2.9 - Приклад згенерованих аніме обличь

Зміна емоцій, віку, виразу обличчя людини - всього цього можна досягти, правильно навчивши і запрограмувавши нейронні мережі GAN. На практиці це виглядає наступним чином: на вході моделі подається вихідне фото і вказується емоція, яку потрібно показати на виході (рис. 2.10).



Рисунок 2.10 - Приклад підміни емоцій на обличчі

Також нейронні мережі GAN використовують для генерації реалістичного відео міського середовища. Наприклад, при створенні фільмів, ігор, віртуальної реальності.

Перетворення начерків і контурних малюнків в фото реалістичне зображення за допомогою GAN відбувається наступним чином: ви малюєте від руки особа, сумку або, наприклад, kota і отримуєте фото реалістичне зображення на виході (рис 2.11).

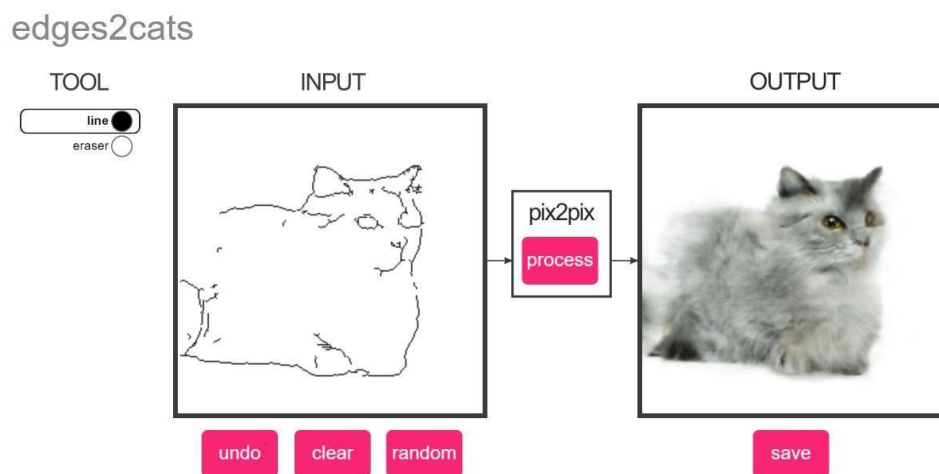


Рисунок 2.11 - Генерація зображення kota по малюнку від руки

Оскільки GAN - досить молодий метод (він з'явився тільки в 2014 році, а перші "пристойні" результати з'явилися в 2016-2017 роках), ще ніхто не знає достовірно, що можна, а чого не можна зробити за допомогою GAN.

2.5 Генеративно-змагальна мережа Spade

Ідея SPADE (рис 2.12) полягає в тому, щоб запобігти втраті семантичної інформації в мережі, дозволяючи мапі сегментації управляти параметрами

нормалізації γ , а також β , локально, на рівні кожного окремого шару. Замість того щоб використовувати тільки одну пару параметрів для кожного каналу, вони обчислюються для кожної просторової точки шляхом подачі карти сегментації зі зниженою дискретизацій через 2 згортальних шару.




Рисунок 2.12 - Алгоритм роботи ГЗМ SPADE

Замість того щоб розгортати карту сегментації на перший шар, SPADE використовує її версії зі зниженою дискретизацій для модуляції нормалізованих вихідних даних для кожного шару.

Генератор SPADE (рис 2.13) об'єднує всю цю конструкцію в невеликі «залишкові блоки», які містяться між шарами підвищує дискретизації (транспонована згортка):

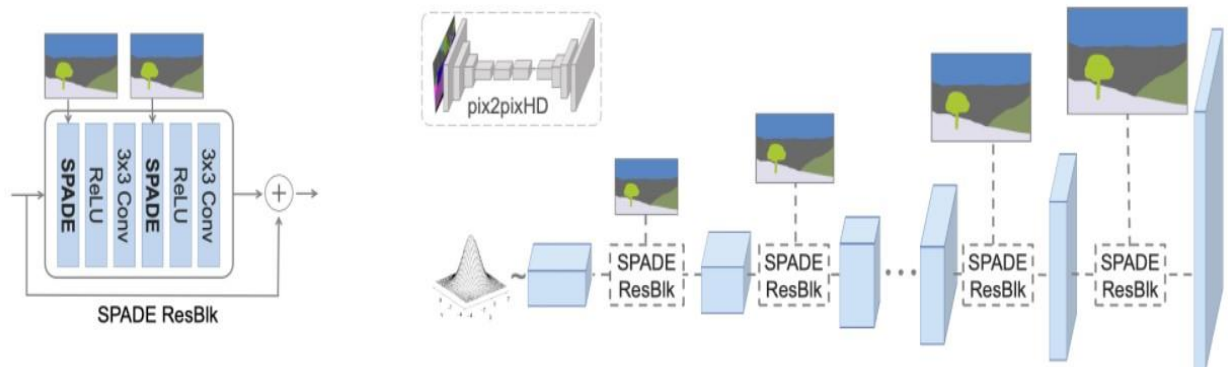


Рисунок 2.13 - Схема роботи ГЗМ SPADE

Високорівнева схема генератора SPADE в порівнянні з генератором pix2pixHD.

Тепер, коли карта сегментації подається «зсередини» мережі, немає необхідності використовувати її в якості вхідних даних для першого шару. Замість цього повернемося до вихідної схеми генеративно-дискримінаційної мережі, в якій в якості вхідних даних використовувався випадковий вектор. Це дає нам додаткову можливість генерувати різні зображення з однієї карти сегментації («Мультимодальний синтез»). Це також робить непотрібним весь «кодирувальник» pix2pixHD, а це серйозне спрощення.

SPADE використовує ту ж функцію втрат, що і pix2pixHD (рис. 2.14), але з однією зміною: замість зведення в квадрат значень VLSGAN в ній використовується hinge loss.

З цими змінами було отримано прекрасні результати:




Рисунок 2.14 - Результати SPADE порівнюються з результатами
pix2pixHD

2.6 Висновок і подальші дослідження

Порівнявши різні методи для покращення зображень було прийняте рішення використовувати саме підхід супер роздільної здатності зображень на основі генеративно-змагальних мереж. Інші методи супер резолюції являються застарілими та показують гірші результати навчання. Використання генеративно-змагальних мереж дозволяє отримати кращі результати на етапі навчання та більшу якість контурів вихідних зображень на підшарах нейронної мережі.

РОЗДІЛ 3 МОДЕЛЬ ПОКРАЩЕННЯ ЯКОСТІ ЗОБРАЖЕНЬ

3.1 Вступ

В цьому розділі буде розібрано реалізацію і розробку моделі для покращення якості зображень з використанням генеративно-змагальної нейронної мережі з використанням методу супер-роздільної здатності. Програмний продукт був реалізований на мові Python. Ця мова була вибрана, тому що на ній реалізовано велика кількість бібліотек, які змогли спростити нам реалізацію багатьох процедур, і можливість натренувати якісну модель.

3.2 Дані на показники подібності

Дослідження проводилися на трьох широко використовуваних наборах тестових даних Set5, Set14 та BSD100, тестовому наборі BSD300. Всі експерименти проводяться з масштабним коефіцієнтом $4\times$ між зображеннями з низькою та високою роздільною здатністю. Це відповідає зменшенню пікселів зображення на $16\times$. Для справедливого порівняння, усі повідомлення PSNR [дБ] та SSIM були розраховані на у-каналі центрально обрізаного, видалення смуги шириною 4 пікселі від кожної межі, зображення за допомогою пакета daala. Зображення BP3 для еталонних методів, включаючи найближчого сусіда, бікубічний, SRCNN та SelfExSR [31], були отримані з онлайн-матеріалу, що доповнює праці Хуанга [31] та Кіма [32]. Статистичні тести проводилися як парні двосторонні тести Вілкоксона зі знаком і значущість визначали при $p < 0,05$.

3.2.1 Підвищення варіативності шляхом стандартного відхилення

Генеративно-змагальні мережі мають тенденцію охоплювати лише підмножину варіацій, знайдених у навчальних даних, і Саліманс та ін. (2016) пропонують як «міні-пакетну дискримінацію» як рішення. Вони не обчислюють статистику особливостей тільки з окремих зображень, але і через міні-серію, заохочуючи таким чином міні-партії генерувати та тренувати зображення для показу подібних статистичних даних. Це реалізується додаванням міні-партії шару до кінця дискримінатора, де шар дізнається великий тензор, який проектує активація вводу до масиву статистики. Окремий набір статистичних даних складається для кожного прикладу в *minibatch*, і він приєднується до виходу шару, щоб дискримінатор міг використовувати статистику внутрішньо. різко спрощуємо такий підхід, одночасно вдосконалюючи різні варіанти.

Спрощене рішення не має ні навчальних параметрів, ні нових гіперпараметрів. спочатку обчислюємо стандартне відхилення для кожної функції у кожному просторовому розташуванні над міні-партією. тоді середні ці оцінки за всіма можливостями та просторовими місцями отримують єдине значення. повторюємо цінують і з'єднують його з усіма просторовими місцями та над міні-партією, отримуючи одну додаткову (постійну) функцію карти. Цей шар можна було б вставити в будь-якому місці дискримінатора, але його знайшли найкраще вставити його до кінця. Експериментували з більш багатим набором статистики, але не змогли додатково покращити варіацію. Паралельно працюючи, Lin та співавт. (2017) надати теоретичну інформацію про переваги показу декількох зображень дискримінатору (рис. 3.1).

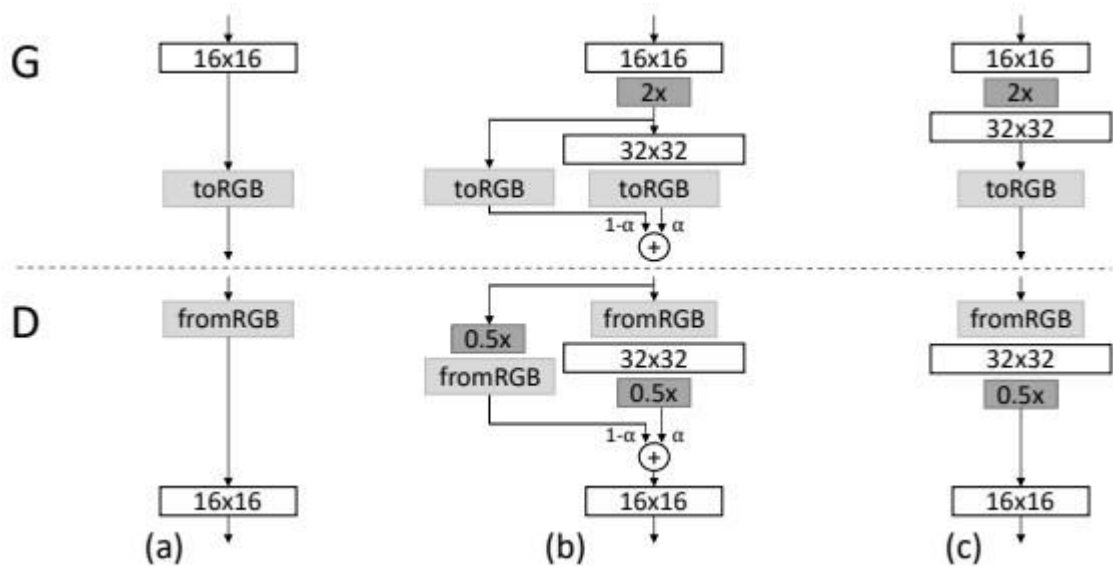


Рисунок 3.1 - При подвоєнні роздільної здатності генератора (G) та дискримінатора (D) згасаємо в нові шари плавно

Цей приклад ілюструє перехід від 16×16 зображень (а) до 32×32 образи (в). Під час переходу (б) розглядаємо шари, які працюють на більш високій роздільній здатності, як а залишковий блок, вага якого α лінійно збільшується від 0 до 1. Тут $2 \times 0,5 \times$ відносяться до подвоєння і вдвічі зменшити роздільну здатність зображення, використовуючи відповідно фільтрування найближчого сусіда та середнє об'єднання. ToRGB являє собою шар, який проектує особливості векторів на RGB кольори та fromRGB зворотний; обидва використовують 1×1 згортки. Навчаючи дискримінатора, подаємось у реальні образи які зменшуються в масштабі, щоб відповідати поточній роздільній здатності мережі. Під час переходу до роздільності інтерполюємо між двома роздільностями реальних зображень, подібно до того, як генератор виводить поєднує дві роздільності.

Альтернативні варіанти варіаційної проблеми включають розкручування дискримінатора Метца регуляризувати його оновлення та "відштовхуючий регуляризатор" Жао, який додає новий термін втрати до генератора, намагаючись заохотити його ортогоналізувати функціональні вектори в міні-партії. Численні генератори Гош, також служать подібній меті.

Визнаємо, що це рішення можуть збільшити варіацію навіть більше, ніж рішення - або, можливо, буде ортогональним для нього - але залиште детальне порівняння на більш пізній час.

3.2.2 Деталі та параметри навчання

Всі мережі навчені використовуючи випадкову вибірку з 350 тисяч зображень із бази даних ImageNet [33]. Ці зображення відрізняються від тестових. Зображення HP3 отримані шляхом дескрипції зображень BP3 (BGR, $C = 3$) з використанням бікубічного ядра з коефіцієнтом зниження дискретизації $r = 4$. Для кожної міні-партії вирізано 16 випадкових 96×96 кадрів зображень BP3 різних навчальних зображень. Потрібно звернути увагу, що можна застосувати модель генератора до зображень довільного розміру, оскільки вона повністю згорнута. Діапазон вхідних зображень HP3 масштабован до $[0, 1]$, а для зображень BP3 до $[-1, 1]$. Таким чином, втрати СКП були розраховані на зображеннях діапазону інтенсивності $[-1, 1]$. Карти функцій ЗМШР також були масштабовані в $1/12,75$ разів, щоб отримати втрати ЗМШР в масштабі, порівнянному з втратою СКП. Це еквівалентно множенню формули 5 з коефіцієнтом масштабування $\approx 0,006$. Для оптимізації використовується $\beta_1 = 0,9$. Мережі SRResNet пройшли навчання із швидкістю навчання 10 в -4 та 10 у 6 ітерацій оновлення. Використана навчена мережа SRResNet на базі СКП як ініціалізацію для генератора при навчанні фактичного ГЗМ, щоб уникнути небажаних локальних оптимумів. Усі варіанти СРГЗМ пройшли навчання з 10 у 5 ітераціями оновлення зі швидкістю навчання 10 в -4 та ще 10 у 5 ітераціями з меншою швидкістю 10 в -5. Чергуються оновлення мережі генератора та дискримінатора, що еквівалентно $k = 1$, як це використано у праці Гудфіла [33]. Дана мережа генераторів має 16 однакових ($B = 16$) залишкових блоків. Під час тестування

вимкнено оновлення пакетної нормалізації, щоб отримати вихід, який детерміновано залежить лише від вхідних даних [33]. Реалізація базується на працях Теано та Лазаньї [33].

3.2.3 Робота над втратою вмісту

Досліджувався ефект різних варіантів втрати вмісту при перцептивній втраті для ГЗМ. Конкретно розслідувався $1SR = 1SRX + 10 - 31SR$ Gen для вказаних втрат вмісту $1SR$ X:

Set5	SRResNet-		SRGAN-		
	MSE	VGG22	MSE	VGG22	VGG54
PSNR	32.05	30.51	30.64	29.84	29.40
SSIM	0.9019	0.8803	0.8701	0.8468	0.8472
MOS	3.37	3.46	3.77	3.78	3.58
Set14					
PSNR	28.49	27.19	26.92	26.44	26.02
SSIM	0.8184	0.7807	0.7611	0.7518	0.7397
MOS	2.98	3.15*	3.43	3.57	3.72*

Рисунок 3.2. Виконання різних функцій збитків для SRResNet та змагальних мереж на базових даних Set5 та Set14.

Оцінка MOS значно вища ($p < 0,05$), ніж при інших втратах у цій категорії. $[4 \times \text{збільшення масштабу}]$. СРГЗМ-СКП: $1SR$ СКП, щоб дослідити змагальну мережу зі стандартною СКП як втрату вмісту. СРГЗМ-ЗМШР22: $1SR$ V GG / 2.2 з $\phi 2,2$, втрата, визначена на картах об'єктів, що представляють функції нижчого рівня. СРГЗМ-ЗМШР54: $1SR$ V GG / 5.4 з $\phi 5,4$, втрата,

визначена на картах особливостей функцій вищого рівня від глибинних мережових шарів з більшим потенціалом зосередити увагу на змісті зображень. Також оцінюється ефективність роботи генераторної мережі без змагального компонента для двох втрат l SR СКП (SRResNet-СКП) і l SR VGG / 2.2 (SRResNet -3МШР22). Потрібно звернути увагу, що під час тренування SRResNet-3МШР22 була додана додаткова загальна втрата варіації з вагою [32]. Кількісні результати узагальнені на рисунку 3.2. Навіть у поєднанні із змагальними втратами СКП пропонує рішення з найвищими значеннями ПБСШ, які, однак, сприймаються досить гладко і менш переконливо, ніж результати, досягнуті з компонентом втрат, більш чутливим до зорового сприйняття. Це спричинено конкуренцією між втратою вмісту на основі СКП та збитковою втратою. Також впливають незначні артефакти реконструкції, які ми спостерігали у меншості реконструкцій на основі СРГЗМ-СКП, до цих конкуруючих цілей. Не вдалося визначити суттєво найкращу функцію втрат для SRResNet або СРГЗМ щодо на Set5. Однак СРГЗМ-3МШР54 значно перевершив інші варіанти СРГЗМ та SRResNet на Set14. Спостерігається тенденція, згідно з якою використання карт функцій 3МШР вищого рівня $\phi_{5,4}$ дає кращі деталі текстури порівняно з $\phi_{2,2}$ (рис. 3.3). Подальші приклади вдосконалення сприйняття за допомогою СРГЗМ над SRResNet наведені далі.




Рисунок 3.3: Кольоровий розподіл оцінок на BSD100

Середнє значення показано червоним маркером, де маркери відцентровані навколо значення 1. [4× збільшення масштабу].

3.3 Висновки до третього розділу

Було проведено порівняння ефективності SRResNet та СРГЗМ з бікубічною інтерполяцією та чотирма сучасними методами. Кількісні результати узагальнені на рисунку і підтверджують, що SRResNet (з точки зору ПВСШ / ІСП) встановлює новий рівень техніки на трьох базових наборах даних. Також було отримано рейтинги подібності для СРГЗМ та інших методів на тестовому наборі даних BSD100. Приклади зображень, надвирішених за допомогою SRResNet та СРГЗМ, зображені далі. Результати, наведені на рисунку, підтверджують, що СРГЗМ значно перевершує всі еталонні методи і встановлює новий рівень техніки для фотореалістичного зображення СРЗ. Усі відмінності є дуже значними для BSD100, крім СРЗНМ. Розподіл усіх зібраних рейтингів наведено на рисунку 3.3.

РОЗДІЛ 4 РОЗРОБКА СТАРТАП-ПРОЕКТУ

Стартап як форма малого ризикового (венчурного) підприємництва впродовж останнього десятиліття набула широкого розповсюдження у світі через зниження бар'єрів входу в ринок (із появою Інтернету як інструменту комунікацій та збуту стало простіше знаходити споживачів та інвесторів, займатись пошуком ресурсів, перетинати кордони між ринками різних країн), і вважається однією із наріжних складових інноваційної економіки, оскільки за рахунок мобільності, гнучкості та великої кількості стартап-проектів загальна маса інноваційних ідей зростає.

Проте створення та ринкове впровадження стартап-проектів відзначається підвищеною мірою ризику, ринково успішними стає лише невелика частка, що за різними оцінками складає від 10% до 20%. Ідея стартап-проекту, взята окремо, не вартує майже нічого. Головним завданням керівника проекту на початковому етапі його існування є перетворення ідеї проекту у працюючу бізнес-модель, що починається із формування концепції товару (послуги) для визначеної клієнтської групи за наявних ринкових умов.

Розроблення та виведення стартап-проекту на ринок передбачає здійснення низки кроків, в межах яких визначають ринкові перспективи проекту, графік та принципи організації виробництва, фінансовий аналіз та аналіз ризиків і заходи з просування пропозиції для інвесторів. Далі наведено маркетинговий аналіз стартап проекту.

В межах цього етапу:

- а) розробляється опис самої ідеї проекту та визначаються загальні напрями використання потенційного товару чи послуги, а також їх відмінність від конкурентів;
- б) аналізуються ринкові можливості щодо його реалізації;
- в) на базі аналізу ринкового середовища розробляється стратегія ринкового впровадження потенційного товару в межах проекту.

4.1. Опис ідеї проекту

В межах підпункту було проаналізовано і подано у вигляді таблиць:

- а) зміст ідеї (що пропонується);
- б) можливі напрямки застосування;
- в) основні вигоди, що може отримати користувач товару (за кожним напрямком застосування);
- г) чим відрізняється від існуючих аналогів та замінників.

Перші три пункти подані у вигляді таблиці (таблиця 4.1) і дають цілісне уявлення про зміст ідеї та можливі базові потенційні ринки, в межах яких потрібно шукати групи потенційних клієнтів.

Таблиця 4.1 - Опис ідеї стартап-проекту

Зміст ідеї	Напрямки застосування	Вигоди для користувача
Дана комплексна система дозволяє розв'язати проблему наявності зображень низької якості.	Створення нових зображень	Зменшення часу, витраченого на створення зображень
	2. Аналіз нових зображень та їх якість	Покращення якості зображень

Аналіз потенційних техніко-економічних переваг ідеї (чим відрізняється від існуючих аналогів та замінників) порівняно із пропозиціями конкурентів передбачає:

- а) визначення переліку техніко-економічних властивостей та характеристик ідеї;

б) визначення попереднього кола конкурентів (проектів-конкурентів) або товарів-замінників чи товарів-аналогів, що вже існують на ринку, та проводиться збір інформації щодо значень техніко-економічних показників для ідеї власного проекту та проектів-конкурентів відповідно до визначеного вище переліку;

в) проводиться порівняльний аналіз показників: для власної ідеї визначаються показники, що мають а) гірші значення (W, слабкі); б) аналогічні (N, нейтральні) значення; в) кращі значення (S, сильні) (табл. 4.2).

Таблиця 4.2 - Визначення сильних, слабких та нейтральних характеристик ідеї проекту

№ п/п	Техніко- економічні характерист ики ідеї	(потенційні) товари/концепції конкурентів		W (слабка сторона)	N (нейтра льна сторона)	S (сильн а сторон а)
		Мій проект	FORecas t 4u			
1.	Точність прогнозува ння	Застосування кращої моделі	Відсутнє прогно зування			+
2.	Ризики невірного прогнозу	Існують, через велику кількіст ь факторів	Відсутні через відсутніс ть проноз у		+	

Продовження таблиці 4.2

3.	Доступність, зручність	Обмежені функції:6 побудова моделі і прогнозування	Власний інтерфейс		+	
----	---------------------------	--	----------------------	--	---	--

Визначений перелік слабких, сильних та нейтральних характеристик та властивостей ідеї потенційного товару є підґрунтям для формування його конкурентоспроможності.

4.2 Технологічний аудит ідеї проекту

В межах даного підрозділу було проведено аудит технології, за допомогою якої можна реалізувати ідею проекту (технології створення товару). Визначення технологічної здійсненності ідеї проекту передбачає аналіз таких складових (таблиця 4.3):

- 1) за якою технологією буде виготовлено товар згідно ідеї проекту?
- 2) чи існують такі технології, чи їх потрібно розробити/додати?
- 3) чи доступні такі технології авторам проекту?

Таблиця 4.3 - Технологічна здійсненність ідеї проекту

№ п/п	Ідея проекту	Технології реалізації	Наявність технологій	Доступність технологій
1	Створення системи конструювання зображень з зображень низької роздільної здатності	Використання мови програмування Python	Наявна	Доступна
		Pytorch	Наявна	Доступна
		Використання мови програмування HTML	Наявна	Доступна
		Docker	Наявна	Наявна
		Обрана технологія реалізації ідеї проекту: мова програмування Python. Бібліотека Pytorch		

За результатами аналізу таблиці зроблено висновок щодо можливості технологічної реалізації проекту. Технологічним шляхом реалізації проекту було обрано такі технології, як Python 3.4 та Pytorch через їх доступність та безкоштовність.

Визначення ринкових можливостей, які можна використати під час 77 ринкового впровадження проекту, та ринкових загроз, які можуть перешкодити реалізації проекту, дозволяє спланувати напрями розвитку проекту із урахуванням стану ринкового середовища, потреб потенційних клієнтів та пропозицій проектів-конкурентів.

Спочатку було проведено аналіз попиту: наявність попиту, обсяг, динаміка розвитку ринку (таблиця 4.4).

Таблиця 4.4 - Попередня характеристика потенційного ринку стартап-проекту

№ п/п	Показники стану ринку (найменування)	Характеристика
1	Кількість головних гравців, од	3
2	Загальний обсяг продаж, грн/ум.од	15000000
3	Динаміка ринку (якісна оцінка)	Зростає
4	Наявність обмежень для входу (вказати характер обмежень)	Ліцензії, регуляторні
5	Специфічні вимоги до стандартизації та сертифікації	+
6	Середня норма рентабельності в галузі (або по ринку), %	250

Середню норму рентабельності в галузі було порівняно із банківським відсотком на вкладення. Останній є меншим, тому є сенс вкладати гроші саме у цей проект.

За результатами аналізу таблиці 4.4 було зроблено висновок, що ринок є привабливим для входження.

Надалі були визначені потенційні групи клієнтів, їх характеристики та сформовано орієнтовний перелік вимог до товару для кожної групи (табл. 4.5).

Таблиця 4.5 - Характеристика потенційних клієнтів стартап-проекту

№ п/п	Потреба, що формує ринок	Цільова аудиторія (цільові сегменти ринку)	Відмінності у поведінці різних потенційних цільових груп клієнтів	Вимоги споживачів до товару
1.	Потреба в відокремленні сигналу від шуму побудови прогнозів.	Аналітики, аналітичні відділи, фермери	Велика кількість даних	Простота використання, висока точність
2.	Створення якісного прогнозу	Користувачі додатку	Цікавить простота у використанні, низька ціна підтримки системи	Швидкість обробки, низька ціна

Після визначення потенційних груп клієнтів було проведено аналіз ринкового середовища: складено таблиці факторів, що сприяють ринковому впровадженню проекту, та факторів, що йому перешкоджають (табл. 4.6, 4.7).

Таблиця 4.6 - Фактори загроз

№ п/ п	Фактор	Зміст загрози	Можлива реакція компанії
1	Конкуренція	Вихід на ринок продуктів з кращими характеристиками	<p>Передбачити додаткові переваги власного програмного продукту (ПП) для того, щоб повідомити про них саме після виходу на ринок конкурентів.</p> <p>Вдосконалення технічних моментів власного продукту.</p> <p>Обрати нову цільову аудиторію і зосередитися на ній: зниження цін.</p>
2	Зміна потреб користувачів	Користувачам необхідне програмне забезпечення з іншим функціоналом	Передбачити можливість додавання нового функціоналу до створюваного ПП

Таблиця 4.7 - Фактори можливостей

№ п/п	Фактор	Зміст можливості	Можлива реакція компанії
1	Конкуренція	Відсутність аналогічного продукту для вітчизняного користувача.	Адаптація програмного продукту до вітчизняних особливостей.

Продовження таблиці 4.7

2	Поява нових методів прогнозування	З'являються нові методи, що будуть швидше та ефективніше прогнозувати показники	Покращити ПП додаванням нового функціоналу, розширення можливостей
3	Поява нових методів моделювання	З'являються нові методи, що будуть швидше, та більш точно моделювати процеси	Покращити ПП додаванням нового функціоналу, розширення можливостей

Надалі було проведено аналіз пропозиції: визначили загальні риси конкуренції на ринку (таблиця 4.8).

Таблиця 4.8 - Ступеневий аналіз конкуренції на ринку

Особливості конкурентного середовища	В чому проявляється дана характеристика	Вплив на діяльність підприємства (можливі дії компанії, щоб бути конкурентоспроможною)
1. Вказати тип конкуренції - монополія	На ринку присутні декілька компаній-конкурентів, але їх товар дещо відрізняється між собою.	Підтримка якості продукту та постійні нововведення, вдосконалення.

Продовження таблиці 4.8

2. За рівнем конкурентної боротьби - міжнародний	Компанії-конкуренти з інших країн	Створити основу ПП таким чином, щоб можна було легко переробити даний ПП для використання у галузях інших країн.
3. За галузевою ознакою - міжгалузева	Продукт може використовуватись для різних галузей	Постійне вдосконалення продукту, що не має прив'язки до сфери
4. Конкуренція за видами товарів: - товарно-видова	Конкуренція між видами ПП, їх особливостями.	Створити ПП, враховуючи недозображення конкурентів
5. За характером конкурентних переваг - нецінова	Вдосконалення технології створення ПП, щоб собівартість була нижчою	Удосконалення моделі. Використання більш дешевих технологій для розробки, ніж використовують конкуренти, але тільки якщо ці технології відповідають необхідним вимогам якості.
6. За інтенсивністю - не марочна	Бренд присутній, але його роль незначна	Реклама, участь у конференціях, семінарах.

Було проведено аналіз конкуренції у галузі за моделлю М. Портера (табл. 4.9).

Таблиця 4.9 - Аналіз конкуренції в галузі за М. Портером

Складові аналізу	Прямі конкуренти в галузі	Потенційні конкуренти	Постачальники	Клієнти	Товари-замінники
	Навести перелік прямих конкурентів	Визначити бар'єри входження в ринок	Визначити фактори сили постачальників	Визначити фактори сили споживачів	Фактори загроз з боку замінників
	SAS Matlab	Наявність вже існуючих рішень	-	Контроль якості продукту	Наявність більш широкого функціоналу, зручнішого інтерфейсу та авторитет (перевірена якість)
Висновки :	Досить інтенсивна конкуренція та боротьба з іншими гравцями	Є можливість і виходу на ринок, але є і конкуренти.	-	Клієнти диктують умови роботи на ринку: зручний інтерфейс	Необхідно випускати ПЗ не гірше, ніж у конкурентів та розширяти функціонал.

За результатами аналізу було зроблено висновок про можливість роботи на ринку з огляду на конкурентну ситуацію. Також було зроблено висновок щодо характеристик, які повинен мати проект, щоб бути конкурентоспроможним на ринку.

Цей висновок був врахований при формулюванні переліку факторів конкурентоспроможності у наступному пункті. На основі аналізу конкуренції, проведеного в таблиці, а також із урахуванням характеристик ідеї проекту (табл. 4.2), вимог споживачів до товару (табл. 4.5) та факторів маркетингового середовища (табл. 4.6, 4.7) визначається та обґрунтовується перелік факторів конкурентоспроможності. Аналіз оформлено у (табл. 4.10).

Таблиця 4.10 - Обґрунтування факторів конкурентоспроможності

№ п/п	Фактор конкурентоспроможності	Обґрунтування (наведення чинників, що роблять фактор для порівняння конкурентних проектів значущим)
1	Багатофункціональність	Жоден конкурент не є настільки багатфункціональним, не здатен на прогноз, чистку шумів та класифікацію сигналів
2	Якість	Можливість використання системи без складних імплементація в існуючу екосистему фермерського господарства
3	Висока якість прогнозу, велика кількість допоміжних статистичних даних	Робота з клієнтами – великими компаніями та окремими спеціалістами

За визначеними факторами конкурентоспроможності (табл. 4.10) проведено аналіз сильних та слабких сторін стартап-проекту (табл. 4.11).

Таблиця 4.11 - Порівняльний аналіз сильних та слабких сторін проекту

№ п/ п	Фактор конкурентоспроможно сті	Бали 1- 20	Рейтинг товарів-конкурентів у порівнянні з ... (назва підприємства)						
			-3	-2	-1	0	+1	+2	+3
1	Якість аналізу	15					*		
2	Простота використання	20			*				
3	Орієнтованість на кінцевого споживача	7					*		

Фінальним етапом ринкового аналізу можливостей впровадження проекту є складання SWOT-аналізу (матриці аналізу сильних (Strength) та слабких (Weak) сторін, загроз (Troubles) та можливостей (Opportunities) (табл. 4.12) на основі виділених ринкових загроз та можливостей, та сильних і слабких сторін (таблиця 4.11). Перелік ринкових загроз та ринкових можливостей було складено на основі аналізу факторів загроз та факторів можливостей маркетингового середовища. Ринкові загрози та ринкові можливості є наслідками (прогнозованими результатами) впливу факторів, і, на відміну від них, ще не є реалізованими на ринку та мають певну ймовірність здійснення. Наприклад: зниження доходів потенційних споживачів – фактор загрози, на основі якого можна зробити прогноз щодо посилення значущості цінового фактору при виборі товару та відповідно, – цінової конкуренції (а це вже – ринкова загроза).

Таблиця 4.12 - SWOT-аналіз стартап-проекту

Сильні сторони: Точність аналізу Простота використання Автономність	Слабкі сторони: Потрібен час для навчання системи Інтерфейс користувача
--	---

Продовження таблиці 4.12

Можливості: Аналіз емоцій людини на основі біосигналів Застосування системи для попередження серцевих нападів	Загрози: Конкуренція
--	--------------------------------

На основі SWOT-аналізу було розроблено альтернативи ринкової поведінки (перелік заходів) для виведення стартап-проекту на ринок та орієнтовний оптимальний час їх ринкової реалізації з огляду на потенційні проекти конкурентів, що можуть бути виведені на ринок. Визначені альтернативи були проаналізовані з точки зору строків та ймовірності отримання ресурсів (таблиця 4.13).

Таблиця 4.13 - Альтернативи ринкового впровадження стартап-проекту

№ п/п	Альтернатива (орієнтовний комплекс заходів) ринкової поведінки	Ймовірність отримання ресурсів	Строки реалізації
1	Ліцензування алгоритму і патентів	85%	6 місяців
2	Створення ПП з подальшим з подальшою інтеграцією в систему автомобіля	75%	18 місяців
3	Створення окремого додатку і девайса, який буде аксесуаром для керма	55%	16 місяців

Після аналізу було обрано альтернативу №1.

4.3 Аналіз ринкової стратегії проекту

Розроблення ринкової стратегії першим кроком передбачає визначення стратегії охоплення ринку: було проведено опис цільових груп потенційних споживачів (таблиця 4.14).

Таблиця 4.14 - Вибір цільових груп потенційних споживачів

№ п/п	Опис профілю цільової групи потенційних клієнтів	Готовність споживачів сприйняти продукт	Орієнтовний попит в межах цільової групи (сегменту)	Інтенсивність конкуренції в сегменті	Простота входу у сегмент
1	Компанії (українські та міжнародні) діяльність яких пов'язана з фінансово- економічною сферами.	Висока	Високий	Сильна	Складно
2	Приватні підприємства міського та міжнародного рівня	Висока	Високий	Сильна	Складно

Продовження таблиці 4.14

3	Приватні підприємства, обласного рівня.	Помірна	Помірний	Помірна	Середня складність
4	Підприємства регіонального характеру	Помірна	Слабкий	Слабка	Просто
5	ФОП, які діють у фінансово-економічній сферах.	Слабка	Слабкий	Слабка	Просто
Які цільові групи обрано:1,2,3					

За результатами аналізу потенційних груп споживачів було обрано цільові групи, для яких буде запропоновано даний товар, та визначено стратегію охоплення ринку - стратегію диференційованого маркетингу (компанія працює з декількома сегментами).

Для роботи в обраних сегментах ринку сформовано базову стратегію розвитку (таблиця 4.15).

Таблиця 4.15 - Визначення базової стратегії розвитку

№ п/п	Обрана альтернатива розвитку проекту	Стратегія охоплення ринку	Ключові конкурентоспроможні позиції відповідно до обраної альтернативи	Базова стратегія розвитку*
-------	--------------------------------------	---------------------------	--	----------------------------

Продовження таблиці 4.15

1		Визначити потреби кожної з груп, розробити відповідно до них стратегії приваблення клієнтів та маркетингової комунікації	Цінова політика, універсальність продукту (миттєве практичне застосування), орієнтованість на кінцевого споживача	Стратегія диференціації
---	--	--	---	-------------------------

Наступним кроком обрано стратегію конкурентної поведінки (таблиця 4.16).

Таблиця 4.16 - Визначення базової стратегії конкурентної поведінки

№ п/п	Чи є проект «першопрохідцем» на ринку?	Чи буде компанія шукати нових споживачів, або забирати існуючих у конкурентів?	Чи буде компанія копіювати основні характеристики товару конкурента, і які?	Стратегія конкурентної поведінки*
1	«Першопроходець»	Шукати нових	Ні	Стратегія заняття конкурентної ніші

На основі вимог споживачів з обраних сегментів до постачальника (стартап-компанії) та до продукту (табл. 4.5), а також в залежності від обраної базової стратегії розвитку (табл. 4.15) та стратегії конкурентної поведінки

(таблиця 4.16) розроблено стратегію позиціонування (таблиця 4.17), що полягає у формуванні ринкової позиції (комплексу асоціацій), за яким споживачі мають ідентифікувати торгівельну марку/проект.

Таблиця 4.17 - Визначення стратегії позиціонування

№ п/п	Вимоги до товару цільової аудиторії	Базова стратегія розвитку	Ключові конкурентоспроможні позиції власного стартап-проекту	Вибір асоціацій, які мають сформувати комплексну позицію власного проекту (три ключових)
1	Легкість розуміння, зручний інтерфейс, надійний, швидкий, точний та достовірний ПП для побудови моделей і прогнозів.	Стратегія диференціації	Позиція на основі порівняння фірми з товарами конкурентів; Відмінні особливості споживача	Економія часу; Зручність застосування; Практичність та точність результату

Результатом виконання підрозділу стала узгоджена система рішень щодо ринкової поведінки стартап-компанії, яка визначає напрями роботи стартап-компанії на ринку.

4.4 Розроблення маркетингової програми стартап-проекту

Сформовано маркетингову концепцію товару, який отримає споживач. Для цього підсумовано результати попереднього аналізу конкурентоспроможності товару (таблиця 4.18). Концепція товару - письмовий опис фізичних та інших характеристик товару, які сприймаються споживачем, і набору вигод, які він обіцяє певній групі споживачів.

Таблиця 4.18 - Визначення ключових переваг концепції потенційного товару

№ п/п	Потреба	Вигода, яку пропонує товар	Ключові переваги перед конкурентами (існуючі або такі, що потрібно створити)
1	Швидкість отримання результату	Швидка побудова моделі та створення прогнозу	Відсутність необхідності звертатися до сторонньої особи/компанії для побудови моделі та прогнозу. Дані компанії-користувача, якими оперує ПП, не передаються третім особам, чого вимагає політика безпеки багатьох компаній.
2	Зручність застосування	Не потрібно мати глибоких знань, для того щоб побудувати модель та спрогнозувати показники	ПП сам обирає необхідний та оптимальний метод для побудови моделі та прогнозу. Не потрібно мати глибоких знань у прогнозуванні для того, щоб користуватися ПП

Продовження таблиці 4.18

3	Практичність та точність результату	Користувач отримує точні (з малою похибкою розбіжності) результати.	Користувач на виході роботи ПП отримує модель та прогноз, котрі відповідають необхідним показникам достовірності та точності. Отриманий прогноз можна використовувати для створення стратегії розвитку підприємства.
---	-------------------------------------	---	--

Розроблено трирівневу маркетингову модель товару: уточнюється ідея продукту та/або послуги, його фізичні складові, особливості процесу його надання (таблиця 4.19).

1-й рівень При формуванні задуму товару вирішується питання щодо того, засобом вирішення якої потреби і / або проблеми буде даний товар, яка його основна вигода. Дане питання безпосередньо пов'язаний з формуванням технічного завдання в процесі розробки конструкторської документації на виріб.

2-й рівень Цей рівень являє рішення того, як буде реалізований товар в реальному/ включає в себе якість, властивості, дизайн, упаковку, ціну.

3-й рівень Товар з підкріпленням (супроводом) - додаткові послуги та переваги для споживача, що створюються на основі товару за задумом і товару в реальному виконанні (гарантії якості , доставка, умови оплати та ін).

Таблиця 4.19 - Опис трьох рівнів моделі товару

Рівні товару	Сутність та складові
I. Товар за задумом	Зручність та швидкість отримання практичного результату щодо побудови моделі та прогнозування процесів.

Продовження таблиці 4.19

II. Товар у реальному виконанні	Властивості/характеристики	М/Нм	Вр/Тх /Тл/Е/Ор
	1. функція побудови моделі процесу		
	2. функція побудови прогнозу		
	Якість: достовірність побудови математичної моделі, достовірність побудови прогнозу		
	Пакування: відсутнє		
	Марка: StatLabs «Forec»		
III. Товар із підкріпленням	До продажу: відсутнє		
	Після продажу: персональна підтримка в обслуговуванні за додаткову платню.		
Вихідний код та математична модель будуть закриті. На ідею зареєстровано патент.			

Наступним кроком є визначення цінових меж, якими необхідно керуватись при встановленні ціни на потенційний товар (остаточне визначення ціни відбувається під час фінансово-економічного аналізу проекту), яке передбачає аналіз ціни на товари-аналоги або товари субститути, а також аналіз рівня доходів цільової групи споживачів (таблиця 4.20). Аналіз проведено експертним методом.

Таблиця 4.20 - Визначення меж встановлення ціни

№ п/п	Рівень цін на товари- замінники	Рівень цін на товари- аналоги	Рівень доходів цільової групи споживачів	Верхня та нижня межі встановлення ціни на товар/послугу
----------	---------------------------------------	-------------------------------------	--	---

Продовження таблиці 4.20

1	1800\$	2500\$	У всіх трьох груп високий рівень доходів	Базова покупка 1000\$
---	--------	--------	--	-----------------------

Наступним кроком є визначення оптимальної системи збуту, в межах якого було прийняте рішення (таблиця 4.21).

Таблиця 4.21 - Формування системи збуту

№ п/п	Специфіка закупівельної поведінки цільових клієнтів	Функції збуту, які має виконувати постачальник товару	Глибина каналу збуту	Оптимальна система збуту
1	Цільові клієнти – компанії, які бажають впровадити у своїй роботі сучасні засоби, які допоможуть отримати вигоду та	Встановлення контактів із споживачами і підтримання їх. Формування попиту і стимулювання збуту.	Один (від виробника одразу	Прямий канал збуту до споживача, мінімізувати збутові
	покращити дохідність. Вони цікавляться сучасними розробками та інноваційними рішеннями, тому відвідують конференції, інтернет-конференції, семінари.	Дослідницька робота зі збору маркетингової інформації. Доробка товару, виходячи з потреб конкретного покупця.	споживачу)	витрати розвитку маркетингового спілкування із споживачем

Останньою складовою маркетингової програми є розроблення концепції маркетингових комунікацій, що спирається на попередньо обрану основу для позиціонування, визначену специфіку поведінки клієнтів (таблиця 4.22).

Таблиця 4.22 - Концепція маркетингових комунікацій

№ п/п	Специфіка поведінки цільових клієнтів	Канали комунікацій, якими користуються цільові клієнти	Ключові позиції, обрані для позиціонування	Завдання рекламного повідомлення	Концепція рекламного звернення
	Цільові клієнти – компанії, які бажають впровадити у своїй роботі сучасні засоби, які допоможуть отримати	Конференції, інтернет-конференції, семінари, огляд професійної літератури,	Позиція на основі порівняння фірми з товарами конкурентів;	- Створення репутації фірмі — виробнику чи посереднику; - збільшення чистого прибутку та	Шукаєте вірний шлях для розвитку вашої компанії? Досить даремно

Продовження таблиці 4.22

вигоду та покращити дохідність. Вони цікавляться сучасними розробками та інноваційними рішеннями, тому відвідують конференції, інтернет-конференції, семінари.	інтернет, періодичні видання у різноманітних (профільних) галузях.	Відмінні особливо сті споживача	рентабельності фірми; - збільшення потоків покупців та обсягів продажу; стабілізація обсягів продажу в період зменшення попиту та загального спаду ділової активності.	гаяти час на вгадування вірної стратегії! Користуйтеся «Forec» і світле майбутнє вашій компанії забезпечено!
--	--	---------------------------------	--	--

Результатом підрозділу стала ринкова (маркетингова) програма, що включає в себе концепції товару, збуту, просування та попередній аналіз можливостей ціноутворення, спирається на цінності та потреби потенційних клієнтів, конкурентні переваги ідеї, стан та динаміку ринкового середовища, в межах якого впроваджено проект, та відповідну обрану альтернативу ринкової поведінки.

4.5 Висновки до четвертого розділу

В даному розділі було проведено аналіз програмного продукту у якості стартап-проекту. Можна зазначити, що у проекті є можливість

комерціалізації, оскільки ринок потребує якісний продукт, що надає автоматичну побудову лікарських речовин.

На ринку наявна монополістична конкуренція, існує декілька фірм-конкурентів, але їх товар дещо відрізняється, тому вихід на ринок не буде легким і потребує грамотної стратегії виходу. Для впровадження ринкової реалізації проекту слід обрати альтернативу, яка передбачає розробку програмного продукту з подальшим розповсюдженням ліцензій та права на використання за певну роялті.

ВИСНОВКИ

Було підтверджено чудові результати сприйняття СРГЗМ за допомогою тестування. Далі показано, що стандартні кількісні показники, такі як ПВСШ та ІСП, не вловлюють та точно оцінюють якість зображення щодо зорової системи людини [33]. Основна увага в цій роботі полягала в якості сприйняття супер-розрішених зображень, а не на обчислювальній ефективності. Представлена модель на відміну від праці Ши [33], не оптимізований для відео СРЗ в режимі реального часу. Однак попередні експерименти з архітектурою мережі свідчать про те, що більш дрібні мережі можуть надати дуже ефективні альтернативи при незначному зниженні якісних характеристик. На відміну від праці Донга [34], було виявлено, що більш глибокі архітектури мережі є корисними. Дизайн ResNet суттєво впливає на продуктивність більш глибоких мереж. Також можна зробити висновок, що ще більш глибокі мережі ($B > 16$) можуть ще більше підвищити ефективність SRResNet, однак це коштує довшого часу навчання та тестування. Також було виявлено, що варіанти СРГЗМ більш глибоких мереж все важче піддаються навчанню через появу високочастотних артефактів.

Особливо важливим у ситуації, коли є задача створити фотореалістичні зображення за допомогою СРЗ є вибір втрати вмісту, як показано на рисунку 1. Найбільш переконливі сприйнятливі результати, які залежать від потенціалу більш глибоких мережеских шарів. Робимо висновок, що карти функцій цих глибинних шарів фокусуються виключно на вмісті, залишаючи при цьому непереборні втрати, зосереджуючись на деталях текстури, які є головною відмінністю між супер-розрізненими зображеннями без змагальних втрат та фотореалістичними зображеннями. Також потрібно зазначити, що ідеальна функція втрат залежить від програми. Наприклад, підходи, які генерують більш дрібні деталі, можуть бути менш придатними для медичного застосування або спостереження. Розробка функцій втрати вмісту, які

описують просторовий вміст зображення, але більш інваріантна до змін у просторі пікселів, ще більше покращить результати при створенні фотореалістичних зображень за допомогою методу СРЗ.




Рисунок 1: Результати реконструкції зображень з використанням різних методів. [4× збільшення масштабу]

Описана глибинна залишкова мережа СРГЗМ, яка встановлює новий рівень техніки в загальнодоступних наборах даних при оцінці за широко використовуваним показником ПВСШ. Виділено деякі обмеження цієї супер-роздільної здатності зображення, орієнтованого на ПВСШ. Використовуючи масштабне тестування, вдалося підтвердити, що реконструкції СРГЗМ для великих коефіцієнтів збільшення (4×) з більшим відривом є більш фотореалістичними, ніж реконструкції, отримані за допомогою сучасних еталонних методів.

Результати були на четвертій міжнародній науково-технічній конференції "Priority directions of science and technology development" [35].

У якості подальшого напрямку дослідження має сенс розглянути питання покращення якості 3D зображень, а також покращення якості потокового відеоконтенту.

ПЕРЕЛІК ПОСИЛАНЬ

1. A. Booth, E. Gerding, and F. McGroarty. Automated trading with performance weighted random forests and seasonality. *Expert Systems with Applications*. 2014. Vol. 31, No. 8. P. 2651–2661.
2. A. Bagheri, H. Mohammadi Peyhani, and M. Akbari. Financial forecasting using ANFIS networks with Quantum-behaved Particle Swarm Optimization. *Expert Systems with Applications*. 2014. Vol. 31, No. 14. P. 6225–6250.
3. Y. Son, D.-J. Noh, and J. Lee. Forecasting trends of high-frequency KOSPI200 index data using learning classifiers. *Expert Systems with Applications*. 2012. Vol. 29, No. 14. P. 11607–11615.
4. I. Aldridge and S. Krawciw. Real-Time Risk: What Investors Should Know About FinTech. in *High-Frequency Trading, and Flash Crashes*. John Wiley & Sons, Inc., Hoboken, NJ, USA, 2017.
5. F. A. De Oliveira, C. N. Nobre, and L. E. Zárate. Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index. Case study of PETR4, Petrobras, Brazil, *Expert Systems with Applications*. 2013 Vol. 30, No. 18. P. 7596–7606.
6. J. H. Niño-Peña and G. J. Hernández-Pérez. Price direction prediction on high frequency data using deep belief networks. *Communications in Computer and Information Science*. 2016. Vol. 657, P. 74–83.
7. A. Marszałek and T. Burczyn'ski. Modeling and forecasting financial time series with ordered fuzzy candlesticks. *Information Sciences*. 2014. Vol. 273, P. 134–155.
8. X. Li, X. Huang, X. Deng, and S. Zhu. Enhancing quantitative intra-day stock return prediction by integrating both market news and stock prices information. *Neurocomputing* 2014. Vol. 132, P. 228–228. 2014.
9. X. Wang, S. Bao, and J. Chen. High-frequency stock linkage and multi-

dimensional stationary processes. *Physica A: Statistical Mechanics and its Applications*. 2017. Vol. 468, pp. 70–83.

10. E. Chong, C. Han, and F. C. Park. Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies. *Expert Systems with Applications*. 2017. Vol. 83, P. 187–205.

11. I. J. Goodfellow, J. Pouget-Abadie, M. Mirza et al.. Generative adversarial nets. In *Proceedings of the 28th Annual Conference on Neural Information Processing Systems 2014, NIPS 2014*. P. 2672–2680. December 2014.

12. S. Iizuka, E. Simo-Serra, and H. Ishikawa. Globally and locally consistent image completion. *ACM Transactions on Graphics*. 2017. Vol. 26, No. 4. Article no. 107.

13. P. Luc, C. Couprie, S. Chintala, and J. Verbeek. *Semantic segmentation using adversarial networks*, *arXiv preprint*. ArXiv, 1611.08308, 2016, arXiv:1611.08308.

14. M. Mathieu, C. Couprie, and Y. LeCun. *Deep multi-scale video prediction beyond mean square error*, *arXiv preprint*. ArXiv, 1511.05330, 2015, arXiv:1511.05330.

15. S. Pellegrini, E. Ruiz, and A. Espasa. Prediction intervals in conditionally heteroscedastic time series with stochastic components. *International Journal of Forecasting*. 2011. Vol. 27, No. 2. P. 308–319.

16. Y. Kara, M. Acar Boyacioglu, and Ö. K. Baykan. Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert Systems with Applications*. 2011. Vol. 28, No. 5. P. 5311–5319.

17. M. Ghiassi, J. Skinner, and D. Zimbra. Twitter brand sentiment analysis: a hybrid system using n-gram analysis and dynamic artificial neural network. *Expert Systems with Applications*. 2013. Vol. 30, No. 16. P. 6266–6282.

18. M. R. Hassan. A combination of hidden Markov model and fuzzy model for stock market forecasting. *Neurocomputing*. 2009. Vol. 72, No. 16-18. P. 3329–3346.

19. W. Huang, Y. Nakamori, and S.-Y. Wang. Forecasting stock market movement direction with support vector machine. *Computers & Operations Research*. 2005. Vol. 32, No. 10. P. 2513–2522.
20. R. Majhi, G. Panda, G. Sahoo, A. Panda, and A. Choubey. Prediction of S&P 500 and DJIA stock indices using particle swarm optimization technique. In *Proceedings of the Proceeding of the IEEE Congress on Evolutionary Computation (CEC '08)*. P. 1276–1282, Hong Kong, China, June 2008.
21. S. S. Appadoo. *Pricing Financial Derivatives with Fuzzy Algebraic Models: A Theoretical and Computational Approach [Ph.D. thesis]*. University of Manitoba, Winnipeg, 2006.
22. A. Thavaneswaran, K. Thiagarajah, and S. S. Appadoo. Fuzzy coefficient volatility ({FCV}) models with applications. *Mathematical and Computer Modelling*. 2007. Vol. 45, No. 7-8. P. 777–786.
23. C. Carlsson and R. Fullér. On possibilistic mean value and variance of fuzzy numbers. *Fuzzy Sets and Systems*. 2001. Vol. 122, No. 2. P. 315–326.
24. A. Thavaneswaran, S. S. Appadoo, and A. Paseka. Weighted possibilistic moments of fuzzy numbers with applications to {GARCH} modeling and option pricing. *Mathematical and Computer Modelling*. 2009. Vol. 49, No. 1-2. P. 252–268.
25. N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov. Dropout: a simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*. 2014. Vol. 15, No. 1. P. 1929–1958.
26. A. M. Rather, A. Agarwal, and V. N. Sastry. Recurrent neural network and a hybrid model for prediction of stock returns. *Expert Systems with Applications*. 2015. Vol. 32, No. 6. P. 3234–3231.
27. R. D. A. Araújo, A. L. I. Oliveira, and S. Meira. A hybrid model for high-frequency stock market forecasting. *Expert Systems with Applications*. 2015. Vol. 32, No. 8. P. 3081–3096.
28. H. Chen, K. Xiao, J. Sun, and S. Wu. A double-layer neural network framework for high-frequency forecasting. *ACM Transactions on Management*

Information Systems (TMIS). 2017. Vol. 7, No. 4. Article no. 11.

29. X. Ding, Y. Zhang, T. Liu, and J. Duan. Deep learning for event-driven stock prediction. In *Proceedings of the 24th International Joint Conference on Artificial Intelligence, IJCAI 2015*. P. 2327–2333, arg, July 2015.

30. Stéphane Mallat. Understanding deep convolutional networks, 2016. URL: <https://arxiv.org/pdf/1601.04920.pdf> (дата звернення: 10.06.2020 р.)

31. Carl Doersch. Tutorial on Variational Autoencoders, 2016. URL: <https://arxiv.org/pdf/1606.05908.pdf> (дата звернення: 10.06.2020 р.)

32. Haleh Akrami, Anand A. Joshi, Jian Li, Richard M. Leahy. Robust Variational Autoencoder, 2020. URL: <https://arxiv.org/pdf/1905.09961.pdf> (дата звернення: 10.06.2020 р.)

33. Mehdi Mirza, Simon Osindero. Conditional Generative Adversarial Nets, 2014. URL: <https://arxiv.org/pdf/1311.1784.pdf> (дата звернення: 10.06.2020 р.)

34. Anders Boesen Lindbo Larsen, Søren Kaae Sønderby, Hugo Larochelle, Ole Winther. Autoencoding beyond pixels using a learned similarity metric, 2016. URL: <https://arxiv.org/pdf/1512.09300.pdf> (дата звернення: 10.06.2020 р.)

35. Майко О.В. Застосування генеративних змагальних мереж для зображень з надвисокою роздільною здатністю. На прикладі медичних зображень, 2020. URL: <https://sci-conf.com.ua/> (дата звернення 15.12.2020 р.)

ДОДАТОК А ЛІСТИНГ ПРОГРАМИ

```

main.py
from model import SRGAN
from utils import input_setup
import numpy as np
import tensorflow as tf
import pprint
import os

flags = tf.app.flags
flags.DEFINE_integer("epoch", 15000, "Number of epoch [15000]")
flags.DEFINE_integer("batch_size", 128, "The size of batch images [128]")
flags.DEFINE_integer("image_size", 33, "The size of image to use [33]")
flags.DEFINE_integer("label_size", 21, "The size of label to produce [21]")
flags.DEFINE_float("learning_rate", 1e-4, "The learning rate of gradient
descent algorithm [1e-4]")
flags.DEFINE_integer("c_dim", 1, "Dimension of image color. [1]")
flags.DEFINE_integer("scale", 3, "The size of scale factor for preprocessing
input image [3]")
flags.DEFINE_integer("stride", 14, "The size of stride to apply input image
[14]")
flags.DEFINE_string("checkpoint_dir", "checkpoint", "Name of checkpoint
directory [checkpoint]")
flags.DEFINE_string("sample_dir", "sample", "Name of sample directory
[sample]")
flags.DEFINE_boolean("is_train", True, "True for training, False for testing
[True]")
FLAGS = flags.FLAGS

pp = pprint.PrettyPrinter()

def main(_):
    pp.pprint(FLAGS.FLAGS.__flags)

    if not os.path.exists(FLAGS.checkpoint_dir):
        os.makedirs(FLAGS.checkpoint_dir)
    if not os.path.exists(FLAGS.sample_dir):
        os.makedirs(FLAGS.sample_dir)

    with tf.Session() as sess:
        srcnn = SRCNN(sess,
                        image_size=FLAGS.image_size,
                        label_size=FLAGS.label_size,
                        batch_size=FLAGS.batch_size,
                        c_dim=FLAGS.c_dim,
                        checkpoint_dir=FLAGS.checkpoint_dir,
                        sample_dir=FLAGS.sample_dir)

        srcnn.train(FLAGS)

if __name__ == '__main__':
    tf.app.run()

```

ДОДАТОК Б ПРЕЗЕНТАЦІЙНІ МАТЕРІАЛИ

Магістерська Дисертація

Методика покращення якості зображень основі генеративних змагальних мереж

Майко Олексій
КА-92мп
ННК "ІПСА"

Данилов В. Я.
професор, д.т.н.
науковий керівник



Вступ

- **Об'єкт дослідження**
Об'єктом дослідження було обрано зображення низької роздільної здатності.
- **Предмет дослідження**
Генеративно-змагальна нейронна мережа, метод супер роздільної здатності (Super Resolution).
- **Мета дослідження**
Дослідити існуючі підходи до покращення роздільної здатності зображень, покращити їх, розробити власний

Постановка



Постановка задачі

- Провести дослідження процесів покращення роздільної здатності зображень.
- Реалізувати розроблений алгоритм та представити результати роботи у вигляді порівнянь з іншими методами.
- Проаналізувати отримані результати.

Актуальність

Вибірка

Актуальність роботи

- Сучасні дрони, МРТ-сканери, які здатні забезпечувати високу роздільну здатність зображення є надто дорогими. Мета: за допомогою нашого методу забезпечити галузі фермерського господарства, медичної діагностики або відеонагляду дешевим якісним ПЗ.



Вибірка для проведення дослідження

У якості вхідних параметрів для навчання і тестування було обрано стандартні тренувальні вибірки:


- Set5
- Set14
- BSD100



Приклад з вибірки Set14

Схема процесу

Щоб отримати зазначений результат, потрібно дотримуватися подібної послідовності дій:



Переведення
зображення

Архітектура
GAN

Генератор

Дискримінатор

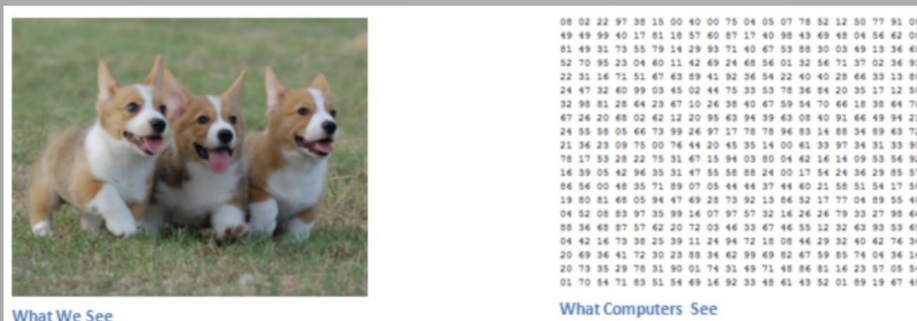
Використання
фільтру

Реконструкція

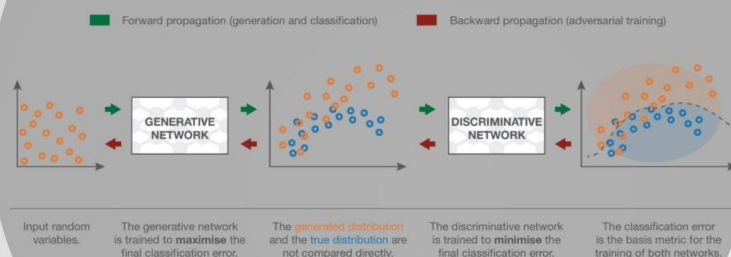
BackProp

Як комп'ютер сприймає зображення

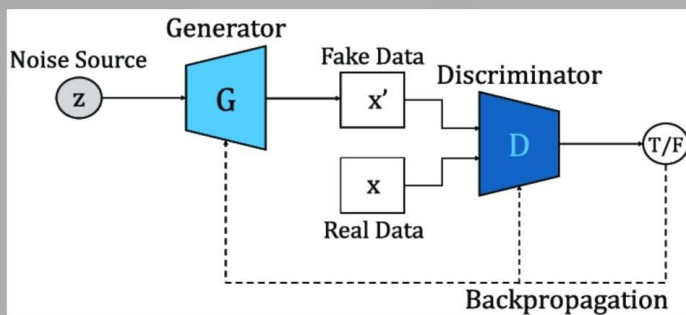
Коли комп'ютер приймає дані на вхід, він бачить масив пікселів. Залежно від дозволу і розміру зображення, наприклад, розмір масиву може бути 32x32x3 (де 3 - це значення каналів RGB). Кожному з цих чисел присвоюється значення від 0 до 255, яке описує інтенсивність пікселя в цій точці.



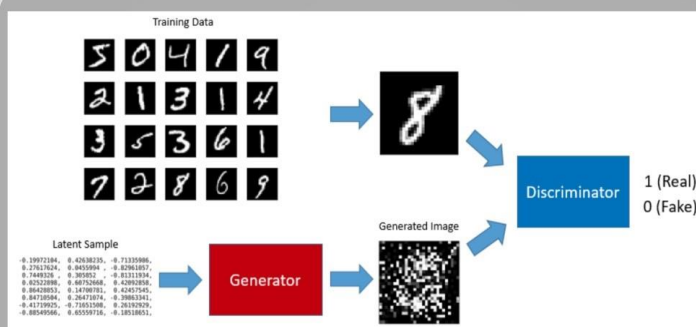
Генеративно-змагальна мережа

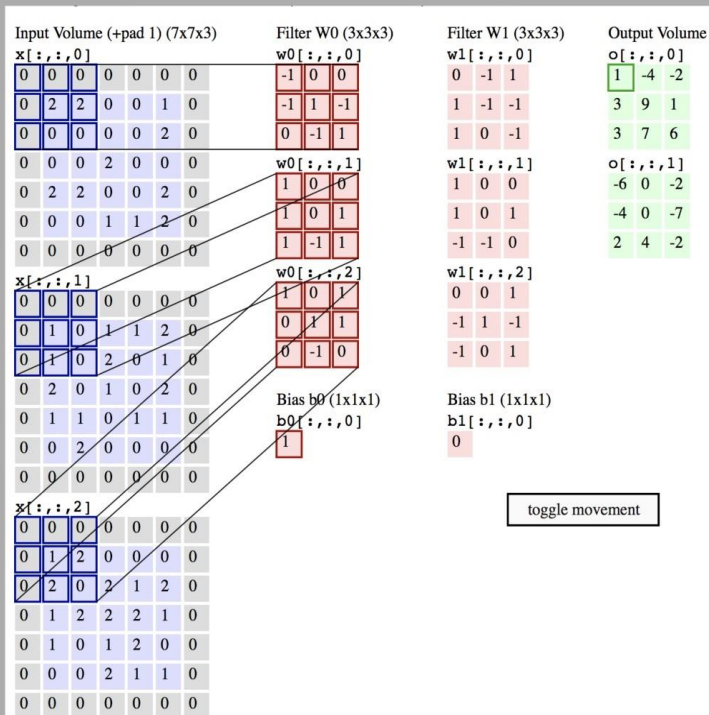



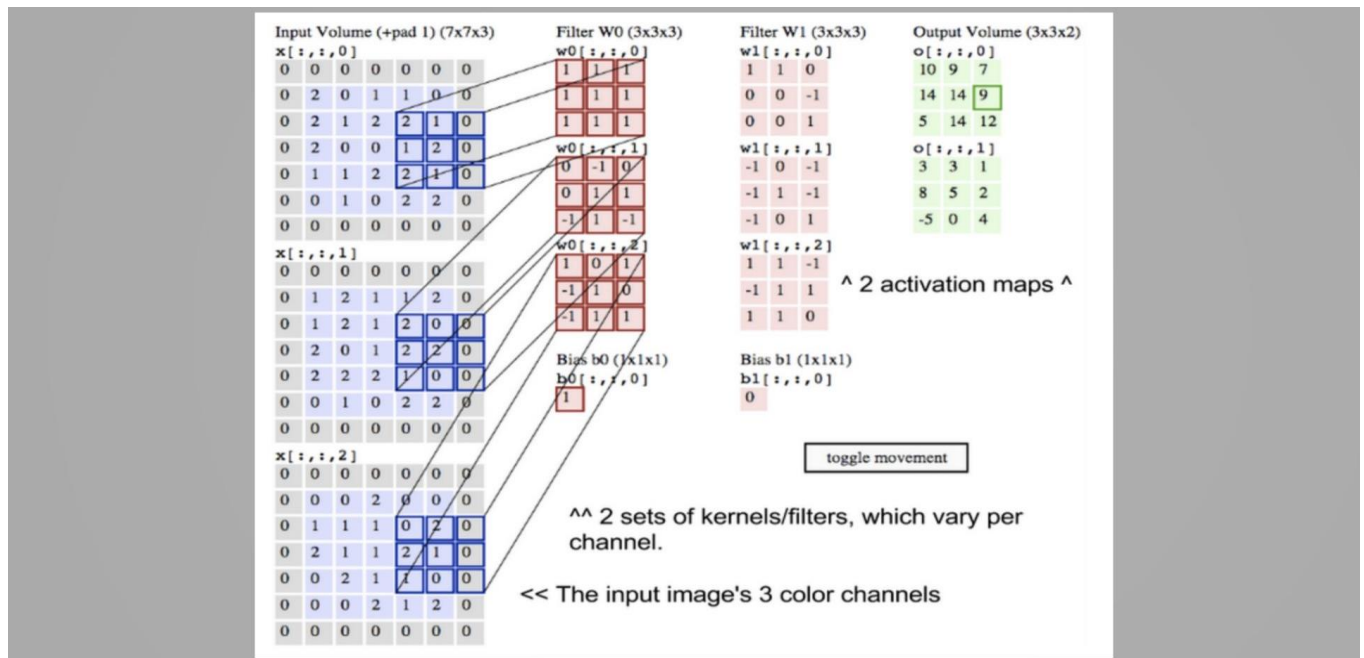
Генератор




Дискримінатор











FP





Forward Propagation







Back Propagation



Приклад
інформації яку
ми отримуємо
на згортках.



Отримання вихідного зображення




Результати

Результатами роботи є порівняння отриманих зображень з початковими наданими у тестових вибірках та порівняння з іншими методами.

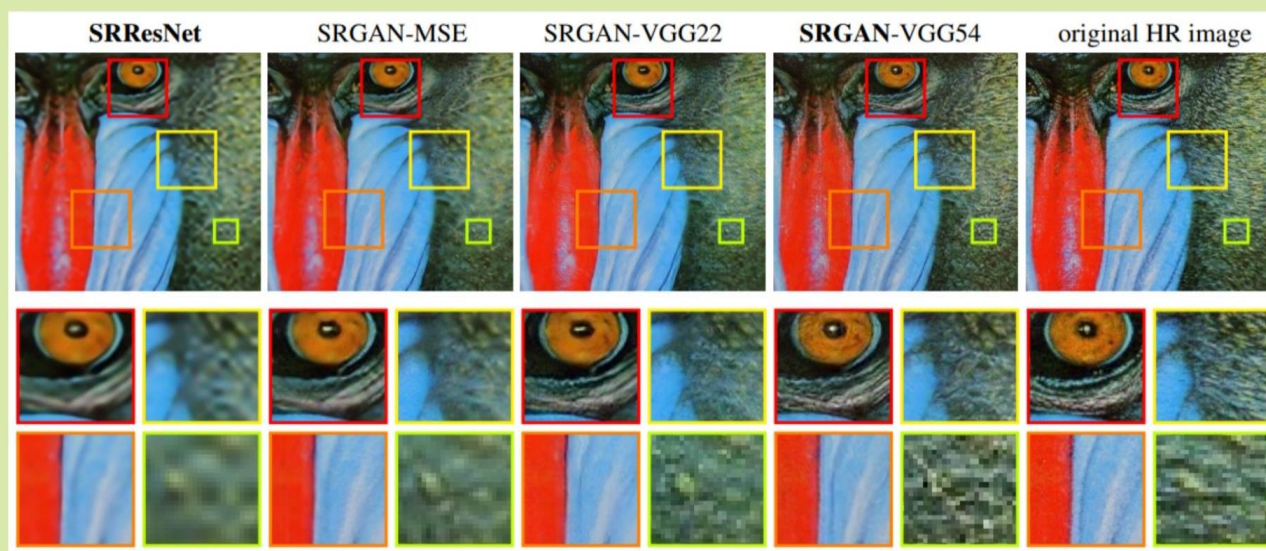
Приклад 1

Приклад 2


Приклад 3



Тестове зображення "Дівчина"



Тестове зображення "Мавпа"



Приклад покращення
результатів роботи SRGAN
зі збільшенням кількості
проведених ітерацій
навчання

Аналіз результатів

Аналіз результатів проводився на
основі параметрів PSNR та SSIM

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} |I(i, j) - K(i, j)|^2$$

$$PSNR = 10 \log_{10} \left(\frac{MAX_I^2}{MSE} \right) = 20 \log_{10} \left(\frac{MAX_I}{\sqrt{MSE}} \right)$$

$$SSIM(x, y) = \frac{(2\mu_x \mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)},$$


Аналіз

Приклад 1

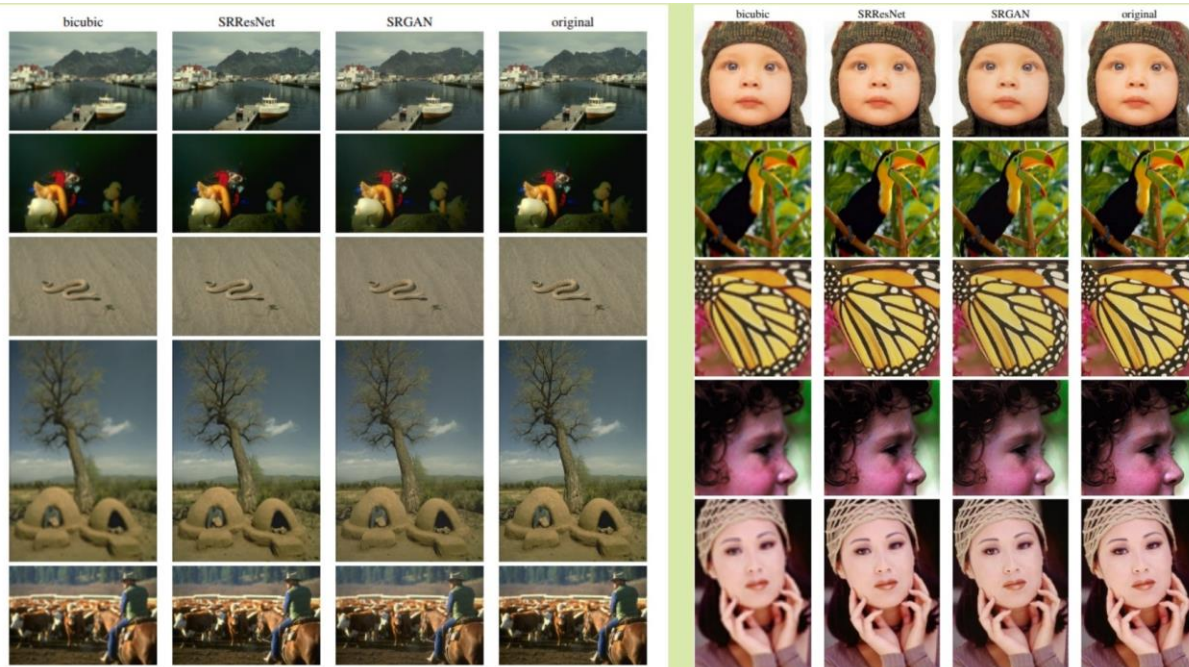
Приклад 2

Set5	nearest	bicubic	SRCNN	SelfExSR	DRCN	ESPCN	SRResNet	SRGAN	HR
PSNR	26.26	28.43	30.07	30.33	31.52	30.76	32.05	29.40	∞
SSIM	0.7552	0.8211	0.8627	0.872	0.8938	0.8784	0.9019	0.8472	1
Set14									
PSNR	24.64	25.99	27.18	27.45	28.02	27.66	28.49	26.02	∞
SSIM	0.7100	0.7486	0.7861	0.7972	0.8074	0.8004	0.8184	0.7397	1
BSD100									
PSNR	25.02	25.94	26.68	26.83	27.21	27.02	27.58	25.16	∞
SSIM	0.6606	0.6935	0.7291	0.7387	0.7493	0.7442	0.7620	0.6688	1

Середні результати PSNR та SSIM для Set5, Set14, BSD100.



Результати роботи різних алгоритмів та порівняння з оригіналом для Set14.



Результати роботи різних алгоритмів для BSD100 (ліворуч) та Set5 (праворуч).

Висновок

- Було проведено дослідження методів покращення роздільної здатності зображень.
- Реалізовано алгоритм та показано результати роботи у вигляді порівнянь з іншими методами.
- Проаналізовано результати за допомогою PSNR та інших методик.

Подальше
дослідження

Дякую за увагу

Подальше дослідження

- Вдосконалення моделі для збільшення швидкості відпрацювання.
- Робота над покращенням якості 3D зображень.
- Робота над збільшенням роздільної здатності відео-контенту (Video Super-Resolution).



Дякую за увагу

